



## 저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

딥 러닝을 이용한 저 전류 영역 2 레벨 인버터  
비선형성 보상 연구

Compensation of 2 Level Inverter  
Nonlinearity at Low Current Region  
Using Deep Learning

2018 년 8 월

서울대학교 대학원

전기정보공학부

이 충 인



딥 러닝을 이용한 저 전류 영역 2 레벨 인버터  
비선형성 보상 연구

Compensation of 2 Level Inverter  
Nonlinearity at Low Current Region  
Using Deep Learning

지도 교수 하 정 익

이 논문을 공학석사 학위논문으로 제출함  
2018 년 8 월

서울대학교 대학원  
전기정보공학부  
이 충 인

이충인의 공학석사 학위논문을 인준함

2018 년 8 월

위 원 장 설 승 기 (인)

부위원장 하 정 익 (인)

위 원 문 승 일 (인)



## 초 록

AC 전동기를 구동하기 위해서 3상 2레벨 전압형 인버터는 보편적으로 사용되어왔다. 하지만 전압형 인버터의 특성상 한 레그의 두 개의 스위치가 동시에 켜질 경우 단락사고로 이어질 수 있다는 단점을 보완하기 위하여 스위치 상태가 변하는 사이에 데드 존을 두게 된다.

하지만 데드존에 의하여 폴 전압의 **duty** 비율이 달라지게 되어 의도했던 전압 지령과 다른 전압이 인가되게 되며 이는 선형시스템을 가정하고 설계하였던 기존 선형 제어기들의 성능을 악화시키는 주요한 원인이 된다. 선형 제어기의 한 예시인 PI 제어기를 전류 제어기로 사용하는 경우 이러한 비선형성은 전압 외란의 형태로 해석할 수 있으며 이 외란은 시스템 반응성을 떨어트리거나 기본파 주파수 대비 6배 주파수의 전류 리플을 발생시킨다.

기존 데드존에 의한 효과를 해소하기 위한 연구로는 전동기를 한 축에 고정시켜놓고 전류 제어를 수행한 뒤 정상상태에서 각 상 전류에 따라서 전압 지령대비 실제 전압의 오차를 1차원 테이블 형태로 저장하여 보상하는 방안이 있다. 이 방법은 전류의 크기가 큰 경우에는 유효하나 저전류 영역에서는 제대로 된 보상을 하지 못하여 오히려 제어를 악화시키는 영향이 있다. 이는 실제 보상이 이루어 지는 과도상태에서 정상상태의 테이블을 적용할 경우 샘플링 시점의 전류가 데드존 구간의 평균 전류를 대표하지 못하기 때문인데 이를 위해 1.5 샘플링 주기 뒤의 전류를 예측하는 방안이 필요하다.

기존 연구에서는 전류를 예측하는데 있어서 선형 모델을 사용하였지만 실제 데드존 구간에서의 전류 파형은 초월함수 형태로 증가하거나 감소하기 때문에 선형적인 모델로는 예측할 수 없다는 한계를 지니고 있다.

따라서 본 논문에서는 딥 러닝 기법을 이용하여 샘플링 시점의 정보를 이용하여 1.5 샘플링 주기 뒤의 보상 전압을 모의하는 함수를 얻는 방법을 제시하고자 한다. 딥 러닝이란 구조적 자유도를 지닌 인공신경망에 변수 최적화 알고리즘을 적용한 분야이다. 인공신경망이란 비선형 활성화 함수를 포함한 여러 시스템들을 입력 변수의 크기에 따라서 선형 보간하는 형태로 만들어진 시스템이기 때문에 뉴런의 개수가 한정되어있지 않다면 이론적으로 어떤 시 불변 비선형 함수도 모의 가능하다. 하지만 지금까지 인공신경망의 비선형적인 구조의 영향으로 인해 변수들을 각각 직관 혹은 주파수 분석을 통해서 설계하는 것이 불가능하였기에 다양한 분야에 적용되지 못하였다. 하지만 프로세서 연산능력의 발달과 다양한 최적화 알고리즘의 개발로 이를 온·오프라인으로 찾는 알고리즘을 적용하는 것이 가능해졌다.

본 논문에서는 이러한 인공신경망의 특성을 이용하여 기존의 방법으로 보상의 한계가 있었던 저속 (0.2p.u.), 저전류 (0.01p.u) 구간에서의 인버터 비선형성을 정지 좌표계에서 모의하였고 이는 1kW 표면 부착형 동기 전동기의 동기 좌표계 PI전류제어를 통해 검증되었다.

주요어 : 인버터 비선형성, 데드타임, 딥러닝, 인공신경망

학 번 : 2016 - 20961

# 목 차

초	록 .....	II
목	차 .....	IV
그림	목차 .....	VI
제 1 장	서 론 .....	1
1.1	연구의 배경 .....	1
1.2	연구의 목적 .....	5
1.3	논문의 구성 .....	6
제 2 장	전류 제어에서 인버터 비선형성의 영향....	8
2.1	SPMSM 구동 시스템 .....	8
2.2	인버터 비선형성 .....	12
2.3	인버터 비선형성이 전류제어 성능에 끼치는 영향..	21
2.4	비선형성을 극복하기 위한 기존 연구의 한계 .....	28
제 3 장	제어분야에서의 딥 러닝 .....	36
3.1	인공신경망 구조 .....	36
3.2	인공신경망 학습 .....	44
제 4 장	딥러닝을 이용한 인버터 비선형성 보상..	56
4.1	인공신경망을 통한 플랜트의 선형화 .....	56
4.2	정지 좌표계 인공신경망 인버터 비선형성 추정기 .	58



<b>제 5 장 실험 결과 .....</b>	<b>67</b>
5.1 실험 세트 구성 .....	67
5.2 보상 성능 검증 .....	68
<b>제 6 장 결론 및 향후 연구 .....</b>	<b>91</b>
<b>참고 문헌 .....</b>	<b>94</b>
<b>부    록 .....</b>	<b>97</b>
<b>ABSTRACT.....</b>	<b>98</b>

## 그림 목차

그림 2.1 3 상 전압형 인버터와 동기 전동기로 구성된 전동기 구동 .....	9
그림 2.2 정지좌표계 A 상 등가회로 .....	10
그림 2.3 PI 전류 제어기 블록도 .....	12
그림 2.4 데드타임에 의한 유효 스위치 파형 (가)전류가 음 방향인 상황(나)전류가 양 방향인 상황 .....	13
그림 2.5 전류 방향과 스위치 조합에 따른 전류 흐름 .....	14
그림 2.6 데드타임이 유효하게 작용하는 구간 .....	15
그림 2.7 전류가 음인 상태의 스위치 변화 시 기생 캐패시터 전압 .....	16
그림 2.8 기생 캐패시터를 고려한 A 상 폴전압 파형 .....	17
그림 2.9 IGBT 음 전류 시 전류 크기에 따른 스위치 ON 파형[19] .....	17
그림 2.10 데드타임에 의한 상 전류에 따라 왜곡되는 폴 전압 .....	18
그림 2.11 DSP 에서 구현된 제어시스템의 샘플링 시점과 전압인가 파형 .....	19
그림 2.12 데드타임이 전류제어 반응성에 끼치는 영향 .....	24
그림 2.13 500R/MIN 구동시 정지좌표계 폴전압 왜란 파형 .....	27
그림 2.14 정지좌표계 전압 외란으로 인한 동기좌표계 D 축 전류제어 .....	27
그림 2.15 오프라인 보상을 위한 정상상태 전압 오차에 대한 피팅 그래프 .....	29
그림 2.16 사다리꼴 보상방법의 저 전류 영역에서의 한계 .....	30
그림 2.17 아크탄젠트 보상 방법의 저 전류 영역에서의 한계 .....	31
그림 2.18 반복제어기를 이용한 인버터 비선형성 상쇄 .....	33

그림 2.19 인공신경망을 이용한 인버터 비선형성 보상 알고리즘 블록도.....	34
그림 2.20 ADALINE 인공신경망 보상기.....	34
그림 3.1 인공신경망 구조.....	37
그림 3.2 인공신경망의 신호 전달 블록도.....	38
그림 3.3 입력함수의 상태에 따른 인공신경망의 활성화.....	38
그림 3.4 활성화함수 (가) RELU, (나) TANSIG, (다) SIGMOID.....	39
그림 3.5 RELU 활성화 함수를 사용한 경우 은닉 뉴런 수에 따른 비선형 모의성능 그래프.....	41
그림 3.6 은닉뉴런 수에 따른 모의 성능 변화.....	41
그림 3.7 활성화 함수의 종류에 따른 인공신경망 비교.....	43
그림 3.8 변수 최적화 알고리즘 블록도.....	44
그림 3.9 비선형 플랜트 모의 인공신경망 학습 블록도.....	45
그림 3.10 인공신경망 PID 이득값 궤적 결정기 학습 블록도.....	46
그림 3.11 오프라인 학습의 학습 데이터 추출 블록도.....	47
그림 3.12 오프라인 학습의 변수 업데이트 블록도.....	48
그림 3.13 온라인 학습의 변수 업데이트 블록도.....	49
그림 3.14 은 SPMSM 속도 PI 제어를 특정 지령 궤적에 대해 운전하였을 때 각 변수 조합에 대한 손실 값을 나타낸 그래프이다. X 표시되어있는 지점이 최소 손실을 가져오는 변수 쌍의 위치이다.....	51
그림 3.15 PI 속도제어기 제어기 이득에 따른 손실 평면.....	51
그림 3.16 GRADIENT DESCENT 를 적용한 속도 PI 제어기 학습과정.....	53

그림 4.1	인공신경망 추정기를 이용한 플랜트의 선형화 블록도[28].....	57
그림 4.2	비선형성과 왜곡을 포함하여 간략화한 SPMSM 전류제어.....	57
그림 4.3	제안하는 시스템의 인공신경망을 이용한 플랜트 선형화.....	58
그림 4.4	정지좌표계에서 인버터 비선형성을 보상하는 인공신경망.....	58
그림 4.5	A 상 인버터 왜곡 전압 인공신경망 추정기.....	59
그림 4.6	상전압 오차 데이터에 대하여 은닉 뉴런 수에 따른 성능 비교 그래프.....	61
그림 4.7	오프라인 학습 데이터 추출 블록도.....	63
그림 4.8	오프라인 학습 데이터 추출을 위한 운전 조건. (가) 전류 운전 조건 변화 파형, (나) 속도 운전 조건 변화 파형, (다) 회전자 각도 데이터 파형, (라) 상 전압 오차 파형.....	64
그림 4.9	오프라인 학습 구조 블록도.....	65
그림 4.10	오프라인 학습 결과 파형.....	65
그림 4.11	온라인 학습 구조 블록도.....	66
그림 5.1	부하전동기와 대상 전동기 M-G 세트와 구동회로.....	68
그림 5.2	성능비교를 위한 보상 알고리즘이 포함된 제어 블록도.....	69
그림 5.3	보상 방법에 따른 THD 비교 그래프.....	70
그림 5.4	보상방법별 모델 상 전압, 상 전류 비교 실험파형.....	71
그림 5.5	전류에 따른 전압 왜곡 양 피팅 그래프.....	72
그림 5.6	Q 축 2A(0.04P.U)제어 실험 시 확인되는 보상 영역.....	74
그림 5.7	2A(0.04P.U)에서 각 보상방법에 따른 전류 파형.....	74

그림 5.8 Q 축 1A(0.02P.U)제어 실험 시 확인되는 보상 영역.....	75
그림 5.9 1A(0.04P.U)에서 각 보상방법에 따른 전류 파형.....	75
그림 5.10 Q 축 0.5A(0.01P.U)제어 실험 시 확인되는 보상 영역.....	76
그림 5.11 0.5A(0.01P.U)에서 각 보상방법에 따른 전류 파형.....	76
그림 5.12 정상상태 부하각에 따른 전류제어 성능 위한 영역 구분.....	77
그림 5.13 상전압 오차 RMS 결과 그래프.....	78
그림 5.14 상전압 오차 PEAK TO PEAK 결과 그래프.....	78
그림 5.15 D 축 전류 오차 RMS 결과 그래프.....	79
그림 5.16 D 축 전류 오차 PEAK TO PEAK 결과 그래프.....	79
그림 5.17 Q 축 전류 오차 RMS 결과 그래프.....	80
그림 5.18 Q 축 전류 오차 PEAK TO PEAK 결과 그래프.....	80
그림 5.19 전류제어기 대역폭 별 각 보상 알고리즘의 상 전압 오차 비교 그래프.....	82
그림 5.20 전류제어기 대역폭 별 각 보상 알고리즘의 동기 좌표계 D 축 전류 오차 비교 그래프.....	83
그림 5.21 전류제어기 대역폭 별 각 보상 알고리즘의 동기 좌표계 Q 축 전류 오차 비교 그래프.....	84
그림 5.22 과도상태 보상실험을 위한 전기각 영역 구분.....	85
그림 5.23 45 도 전기각 위치.....	86
그림 5.24 45 도 전기각 위치에서의 과도상태 보상 실험.....	86
그림 5.25 15 도 전기각 위치.....	87

그림 5.26 15 도 전기각 위치에서의 과도상태 보상 실험.....	87
그림 5.27 -15 도 전기각 위치.....	88
그림 5.28 -15 도 전기각 위치에서의 과도상태 보상 실험.....	88
그림 5.29 -45 도 전기각 위치.....	89
그림 5.30 -45 도 전기각 위치에서의 과도상태 보상 실험.....	89
그림 5.31 3KHZ 전류제어기 대역폭에서의 과도상태 보상 실험. ....	90

# 제 1 장 서 론

## 1.1 연구의 배경

전동기를 구동하기 위한 회로는 전동기의 종류에 따라 혹은 전동기를 구동하는 제어 방식에 따라 발전이 이루어졌다. 그 중 풀 브릿지를 이용한 전압형 인버터는 AC전동기, DC전동기 등에 관계 없이 대중적으로 쓰이며 관련된 연구가 많이 진행되어왔다. 그 중 3상 AC 전동기는 세 상의 선간 전압을 이용하여 전동기에 회전자계를 형성하며 구동시켜야 한다. 이를 위하여 전압형 인버터인 3상 2레벨 인버터는 각각의 레그의 독립적인 2 종류의 풀 전압( $+\frac{V_{dc}}{2}$  혹은  $-\frac{V_{dc}}{2}$ )을 통하여 전동기의 선간 전압을 정의한다. 2 레벨 인버터는 풀 전압을 독립적으로 인가하기에 적합한 구조를 지니고 있으며 각 레그는 독립적인 스위치 조합을 지닐 수 있다. 하나의 레그는 2개의 스위치로 구성되어 있으며 윗상 스위치는 해당 노드를 중성단 대비  $+\frac{V_{dc}}{2}$  전위에 위치시키게 하고 아랫상 스위치는 해당 노드를 중성단 대비  $-\frac{V_{dc}}{2}$  전위에 위치시키게 한다.

전압형 인버터는 사용하기에 간편하지만 한 가지 단점이 있다. 각 레그 사이에는 독립적인 스위치 조합을 가질 수 있지만 한 레그 내의 두 개의 스위치의 상태는 독립적인 상태를 가질 수 없다. 두 개의 스위치가 동시에 켜지는 경우 서로 다른 전위인  $+\frac{V_{dc}}{2}$ 와  $-\frac{V_{dc}}{2}$ 가 만나게 되어 단락사고가 일어나기 때문이다. 따라서 같은 레그 내의 스위치는 항상 상보적인 스위치 상태를 갖도록 스위치 신호가 결정되지만 상보적이라 하더라도 스위치 온·오프 PWM 신호와 스위치의 실제 온·오프 상태 변화 사이에 지연이 있어 스위치 조합이 변경되는 순간에 레그 내 켜져 있던 스위치가 미처 꺼지기 이전에 꺼져 있던 스위치가 켜지는 경우 단락 사고가 발

생한다. 이러한 단락 사고를 막기 위해서 스위치 조합을 변경하기 전에 두 스위치를 모두 끄는 ‘데드 존’을 두게 되며 데드 존을 유지하는 시간을 ‘데드 타임’이라고 한다. 데드 존은 사고를 미연에 방지하기 위한 구간이므로 스위치 온·오프 시간을 고려하여 여유를 두고 설정한다. 하지만 인버터의 폴 전압은 한 스위치 주기 동안의 평균 전압으로 결정되기 때문에 데드 존이 생김으로 인해 각 스위치 조합에 머무르고 있는 시간의 의도했던 바와 달라져 지령 폴 전압과 실제 인가되는 폴 전압이 달라지게 된다. 이러한 왜곡 효과는 제어기 입장에 외란으로 영향을 끼치며 이 외란에 의해서 최대 제어 대역폭이 저하되거나 리플이 발생하게 된다.

이 데드존에 의해서 발생한 외란의 효과를 줄이기 위해서 통상적인 외란을 억제하는 방법인 외란을 추정해서 전향 보상하는 연구가 주로 이루어져 왔다. 외란을 추정하는 방법은 크게 두 가지가 있다. 전동기 모델을 이용해서 외란을 간접적으로 얻는 외란 관측기를 이용한 방법[1-3]과 외란의 모델을 이용하여 직접적으로 외란을 얻는 방법[4-17]이다.

외란 관측기를 이용한 연구[1-3]는 상태 방정식을 이용하여 상 전압 지령과 전동기 모델을 통해 추정한 추정 상 전압의 차이를 이용하여 외란을 관측한다. 이 연구에서는 한 샘플 이내에서의 외란의 변화는 없다고 가정하였으며 전동기 모델의 불완전성의 영향과 노이즈를 제거하기 위해서 저역 필터를 사용하였다. 하지만 저 전류 영역대에서는 한 샘플 이내에서의 전류 변화에 의한 외란의 크기가 무시할 수 없으며 저역 필터를 이용할 경우 발생하는 지연에 의해서 보상 오차는 더욱 커진다. 또한 외란의 주파수는 전동기 회전 속도에 따라서 달라지게 되는데 이에 따라 저역 필터가 가변해야 하지만 [1]에서는 저역 필터의 주파수를 고정하였기 때문에 정확한 보상의 한계가 있다.

외란의 모델을 이용하여 직접적으로 외란을 구하는 연구는 다시 두 가



지로 나뉜다. 외란의 원인을 회로적인 분석을 통하여 모델링하는 방법 [11-17]과 외란에 의해서 발생한 현상을 관측하여 모델링하는 방법[4-10]으로 나뉘어 연구되어 왔다.

첫 번째 회로적인 분석을 통한 모델링 방법은 전압 외란이 전압 지령 대비 실제 걸리는 전압의 차이에서 발생한다는 점에 주목하여 전압 차이를 만드는 인버터 요소를 분석하는 방법으로 이루어져 왔다. [11, 13]는 데드타임에 의한 이상적인 듀티 변화 외에도 스위치 턴 온·오프 지연시간, 스위치와 다이오드의 내부 저항에 의한 전압 강하를 고려하였다. 특히 [13]은 전류 방향에 따라 스위치 혹은 다이오드의 전압 강하가 다를 수 있다는 부분에 초점을 맞추어 분석하여 외란을 추정하였다. [12, 14]은 상 전류의 부호가 바뀌는 시점에서 전류가 영 전류에 머무르는 영 전류 클램핑 현상을 설명하기 위하여 데드 존에서의 회로를 분석하였고 이를 기반으로 외란을 계산하여 보상하였다. [12, 14]에서는 영 전류 클램핑 현상의 원인을 데드 존 구간에서 전원과 회로가 차단되어 인덕터에 에너지를 공급하여 전류를 음 혹은 양으로 증가시킬 수 있는 방법이 없어 저항에 의해 전류의 크기가 줄어드는 것으로 언급하였다. 하지만 이는 [16, 17]에서 언급된 스위치 소자의 기생 캐패시터의 영향을 고려하면 데드 존에서 에너지 공급원이 사라진다는 주장이 설득력을 잃게 된다. [17]에서는 기생 캐패시터의 효과를 고려하여 상 전류에 따른 상 전압 왜곡 값의 그래프가 저전류 영역에서 값이 작아지는 것을 확인하였고 이를 테이블 형태로 저장하여 상 전류에 따른 외란을 테이블에 의해 얻어내어 보상하는 방법을 제안하였다. 이 테이블을 간략화 하기 위하여 [15]는 사다리꼴 모양으로 실시간으로 근사하여 보상하였다.

두 번째 외란에 의해서 발생한 현상을 관측하여 외란을 모델링 하는 방법은 상 저항의 증가에 초점을 맞춘 연구[4, 6]와 전류 고조파에 초점

을 맞춘 연구[5, 7-10]로 나뉘어 진다. [4, 6]는 데드타임에 의한 전압 외란이 안정성에 끼치는 효과를 분석하기 위해서 외란이 전류와 동상인 점에 주목하여 등가 상 저항으로 모델링 하였다. 또한 [5, 7-10]들은 인버터 비선형성이 동기 좌표계에서 기본파의 6 고조파 형태의 전류 리플을 발생시킨다는 점에 주목하여 동기 좌표계에서 6고조파의 전압의 형태로 보상을 시도한 연구들이다. [7-10]는 6고조파 사인 코사인을 직접적으로 얻어내어 보상을 시도한 연구들이며 [5]는 6고조파 형태로 각도에 따라 보상값이 결정된다는 점에 주목하여 각도에 따라서 보상값을 실시간으로 테이블 형태로 저장한 뒤 보상하는 반복 학습 제어[18]를 사용하였다.

위 논문들 중 [12]를 제외하고는 AD 변환과 알고리즘 계산을 위한 1.5 샘플링 주기의 시지연에 의한 샘플링 시점과 데드 존에서의 전류 차이를 고려하지 않았다. 전류의 크기가 큰 영역에서는 1.5 샘플링 주기의 전류의 차이가 상 전류 대비 크게 영향을 끼치지 못하지만 전류의 크기가 작은 영역에서는 상 전류 대비 전류 변화가 작지 않다. 또한 기생 캐패시터의 영향으로 인하여 상 전류가 작은 영역에서 전류 변화에 따른 전압 변화의 기울기가 더 커져 이 영역에서 샘플링 시점의 전류를 이용하여 보상 전압 값을 결정하는 연구들[11, 13, 14, 16, 17]은 오차를 발생시킨다. 또한 [12]의 경우는 전류를 예측하여 보상을 하였으나 기생 캐패시터의 영향을 고려하지 않았으며 전류가 선형적으로 증가한다는 가정을 사용하였기 때문에 오차가 발생할 수 있다.

[5, 9, 10, 15]와 같이 온라인으로 보상 시스템의 변수를 변화시키는 연구의 경우 구조에서 반영하지 못하는 비선형성이나 외란에 영향을 끼치지만 고려되지 못한 입력 변수의 변화를 대처할 수 있다. 하지만 학습 속도보다 빠른 변화에 대해서는 더 큰 오차를 유발할 수 있기 때문에 온라인이라고 하더라도 변화를 담을 수 있는 변수를 입력 변수로 삼는 구조

를 선택하여야 한다. 그러나 전류를 예측하기 위해서 필요한 상전압, 역기전력 등의 입력 변수가 포함된 구조를 가지는 시스템은 없다.

따라서 본 논문은 상 전류, 상 전압, 역기전력을 입력 변수로 선정하여 전류를 예측하기 위하여 필요한 변수를 입력변수로 선정하며 기생 캐패시터 효과와 전류의 비선형적인 증가를 모델링 할 수 있는 인공신경망 구조를 이용하여 보상 시스템을 설계 하였다.

## 1.2 연구의 목적

인버터 비선형성에 의한 전압 외란을 직접 모델링하는 보상 알고리즘은 다음 세가지 조건을 만족하여야 한다. 첫째로 기생 캐패시터 효과가 고려된 외란 모델의 비선형성을 모의할 수 있는 구조여야하며, 둘째로 1.5 샘플링 주기 동안의 시 지연에 의한 전류 변화량을 예측하기 위한 변수들이 시스템 입력변수로 선정되어야 하며 셋째로 온도 변화, 전류 센서 오차 등 느린 변화에 대해서 대처할 수 있도록 온라인에서 변수 값들이 업데이트 될 수 있어야 한다.

본 논문에서는 이 세가지 조건을 충족시키기 위하여 딥 러닝을 이용한 인버터 비선형성 보상 알고리즘을 제시한다. 딥 러닝이란 인공신경망과 학습의 개념을 합친 알고리즘을 일컫는 용어이다. 인공신경망은 비선형 활성화 함수의 특성을 이용하여 다양한 비선형 시스템을 모의할 수 있는 구조에서의 자유도를 가진 시스템이다. 하지만 활성화된 뉴런의 상태에 따라서 가변하는 시스템이기 때문에 주파수 영역에서 수십 개의 변수를 기존 보드 선도 혹은 영점 극점 분석 등의 설계 방식에 의존해서 설계하는 것이 어렵다. 따라서 모의하고자 하는 시스템에 적합한 최적의 변수를 찾기 위해서 변수 최적화 알고리즘이 적용되며 이 과정을 학습이라 한다.

본 논문에서는 인공신경망의 비선형성적인 시스템 구조를 통해 샘플링된 정보들로부터 전류 예측과 예측된 전류에 의한 왜곡되는 폴 전압까지의 시스템을 모의할 것이다. 인공신경망의 비선형성을 이용하였기 때문에 전류가 선형적으로 증가한다는 가정을 이용하지 않았다. 또한 학습 단계를 오프라인과 온라인으로 나누어 오프라인 학습의 시간 제약이 없다는 장점을 이용하여 전역 최적화 알고리즘을 적용하였고 온라인 학습에서는 실시간으로 변동하는 변수 변동이나 전류의 측정오차를 보정하기 위해 국소 최적화 알고리즘을 활용하였다. 마지막으로 정지 좌표계 회로 분석을 통하여 인공신경망의 입력 변수를 상 전압( $V_{as}$ ), 상 전류( $I_a$ ), 역기전력( $E_a$ )으로 선정하여 상 전류 크기 변화, 상 전압 지령 변화, 부하 각 변화, 속도 변화 등에 대응할 수 있도록 시스템을 설계하였다.

제안하는 보상 알고리즘의 성능을 검증하기 위해서 네 가지 조건에서 1kW SPMSM와 IGBT 인버터(310V, 50A)를 이용하여 실험을 진행하였다. 네 가지 실험은 세 가지 정상상태 운전 시험과 한가지 과도 상태 운전 시험으로 구성되어 있는데 정상상태 실험은 전류 크기에 따른 보상 실험(0.04p.u, 0.02p.u, 0.01p.u), 부하 각에 따른 보상 실험( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ,  $180^\circ$ ,  $225^\circ$ ,  $270^\circ$ ,  $315^\circ$ ), 전류 제어기 대역폭에 따른 실험(300Hz, 600Hz, 900Hz, 1200Hz, 1500Hz)이며 과도 상태 실험은 회전자 각 상태( $\frac{\pi}{8}$ ,  $\frac{\pi}{12}$ ,  $-\frac{\pi}{12}$ ,  $-\frac{\pi}{8}$ )에 따라 전류 크기 step 변화(0.01p.u) 실험을 진행하여 성능을 검증하였다.

### 1.3 논문의 구성

서론을 제외한 논문은 네 가지 장으로 구성되어있다. 2장에서는 서론에서 간략히 언급한 인버터 비 선형성의 원인 중 데드존에 의해서 발생하는 전압 왜곡과 전압 왜곡이 전류 제어에 끼치는 영향에 대해서 살펴

본다. 2.1절에서는 3상 동기 전동기 구동 시스템에 대해서 분석한다. 2.2절에서는 인버터 비 선형성에 의해서 전압 왜곡이 발생하는 원리와 전압 왜곡의 크기에 대해서 분석한다. 특히 전압 왜곡이 어떤 변수의 영향을 받는지 알아본다. 2.3절에서는 2.2절에서 발생한 전압 왜곡이 전류 제어에 끼치는 영향에 대해서 분석한다. 2.4절에서는 이러한 비선형성을 극복하기 위한 기존 연구를 오프라인/온라인으로 나누어 분석하고 그 한계에 대해서 분석한다.

3장에서는 인공신경망의 구조와 학습에 대해서 알아본다. 3.1절에서 다룰 인공신경망의 구조에서는 인공신경망의 구성요소인 뉴런, 변수, 활성화 함수에 대해서 알아보고 각각의 변화가 시스템에 어떻게 영향을 끼치는지 분석한다. 3.2절에서는 인공 신경망 학습 절차에 대해서 알아본다. 각각의 학습 절차에서 어떤 다양성이 있을 수 있고 각각의 방법에 따라서 인공신경망의 변수가 어떤 방식으로 학습되는지 예시를 통해서 확인한다.

4장에서는 인버터 비선형성을 보상하기 위한 인공신경망을 제안한다. 인공신경망의 구조를 제안함과 더불어 인공신경망을 학습하는 방법을 제안하여 2장과 3장의 내용을 본 알고리즘에 적용하는 절차에 대해서 제시한다.

5장에서는 다양한 부하 조건과 제어기 대역폭에 따라서 제안하는 보상 방법의 효과를 1kW SPMSM 전동기와 IGBT 인버터(310V, 50A)를 대상으로 실험한 결과를 통해 분석한다.

## 제 2 장 전류 제어에서 인버터 비선형성의 영향

산업계에서 전류 제어기로 가장 많이 쓰이고 있는 PI제어기는 구현상 간편함과 안정성으로 인하여 다양한 어플리케이션에 사용되고 있다. 하지만 선형 제어기의 특성상 플랜트의 비선형적인 특성에 대해서 대응하기에 한계가 있다. 본 장에서는 SPMSM을 3상 풀 브릿지 전압형 인버터 (Voltage source inverter, VSI)로 구동하는데 있어서 필연적으로 필요한 데드타임에 의해서 발생하는 인버터 비선형성이 전류 제어에 끼치는 영향에 대해서 살펴보고자 한다.

2.1절에서는 SPMSM 구동 시스템에 대해서 다룬다. 선형시스템을 가정한 정지 좌표계 플랜트 모델의 전압방정식을 다루고 DC 지령을 통해서 토크와 자속을 제어하기 위한 동기 좌표계 전압 모델로의 회전 변환과 이를 제어하기 위한 선형제어기인 PI 제어기 이득값 선정 방법에 대해서 다룬다. 2.2절에서는 2.1절에서 가정한 플랜트의 선형성이 성립하지 않는 이유 중 가장 큰 요인인 인버터 비선형성에 대해서 다루고자 한다. 2.3절에서는 데드 타임에 의한 전압 왜곡이 PI 제어기를 이용한 전류 제어에 끼치는 영향 두 가지에 대해서 다루어 보고자 한다. 첫 번째 영향은 최대 전류 제어 성능 제한 효과이고 두 번째 영향은 정지 좌표계 전류 파형 왜곡에 의한 동기 좌표계 전류 리플이다.

### 2.1 SPMSM 구동 시스템

SPMSM 구동시스템은 전동기와 인버터를 포함한 회로와 회로를 구동시키는 신호를 계산하는 제어 시스템으로 나뉜다. 회로는 AC 전동기를 구동하기 위하여 직류단 전압을 AC로 바꾸기 위한 3상 전압형 인버터와 R, L이 직렬로 결합되어있는 3상 평형 회로인 전동기로 구성되어있다. 제어

시스템은 DSP에 코드 형태로 구성되어 있으며 AC 전동기를 DC 전동기를 제어하듯 제어하기 위하여 좌표축을 회전자 위치로 회전 변환시키는 부분(Clarke & Park의 변환)과 PI 제어기로 구성되어있다. 본 절에서는 구동 시스템의 구성요소인 회로와 회로의 전기적 해석인 전압방정식에 대해서 다루고 또 다른 구성요소인 제어 시스템에 대해서는 이득값 선정과 그에 따른 대역폭 선정에 대해서 다룬다.

### 2.1.1 전동기 모델

표면 부착형 영구자석 동기 전동기(SPM)를 구동하는 일반적인 회로는 3상 2레벨 인버터로서 그림 2.1와 같이 표현할 수 있다.

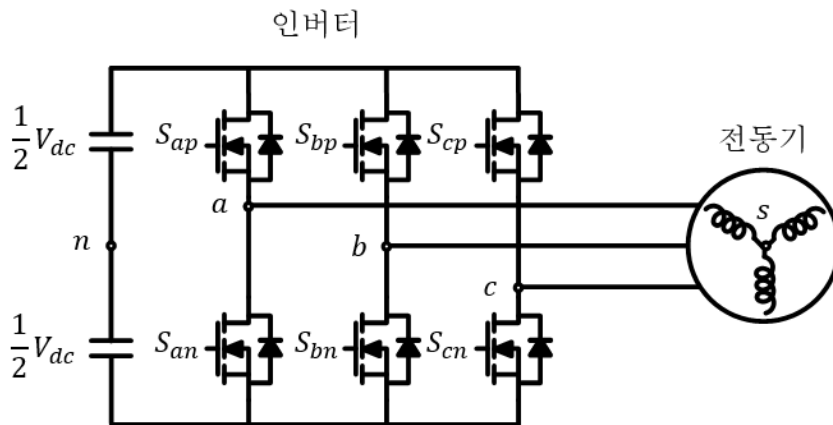


그림 2.1 3상 전압형 인버터와 동기 전동기로 구성된 전동기 구동 시스템.

2레벨 인버터는 전동기의 상 노드의 전위를  $\frac{1}{2}V_{dc}$  혹은  $-\frac{1}{2}V_{dc}$ 로 만들어 전동기의 선간 전압에 원하는 전압을 인가하는 방식으로 전력을 공급한다. 전동기는 3상 대칭형 회로로서 인덕터와 저항의 직렬 연결인 회로로 등가 모델을 만들 수 있으며 그 중 한 상을 회로로 표현하면 그림

2.2와 같다.




그림 2.2 정지좌표계 A상 등가회로.

3상이 모두 대칭으로 구성되어있기 때문에 세 회로에 대한 전압방정식을 하나의 식 (2.1)과 같이 표현할 수 있다.

$$V_{abcs} = R_s I_{abcs} + L_s \frac{dI_{abcs}}{dt} + E \quad (2.1)$$

$$\left( V_{abcs} = \begin{bmatrix} V_{as} \\ V_{bs} \\ V_{cs} \end{bmatrix}, I_{abcs} = \begin{bmatrix} I_a \\ I_b \\ I_c \end{bmatrix}, E = \begin{bmatrix} -\omega_r \lambda_f \sin(\theta_r t) \\ -\omega_r \lambda_f \sin(\theta_r t - \frac{2}{3}\pi) \\ -\omega_r \lambda_f \sin(\theta_r t + \frac{2}{3}\pi) \end{bmatrix} \right)$$

### 2.1.2 동기 좌표계 PI 전류 제어 시스템

동기 좌표계에서의 PI제어는 자속 축과 동기화된 좌표 평면으로 회전 변환된 영역에서 제어를 수행함으로써 AC 전동기임에도 불구하고 DC 전동기와 같은 방식으로 DC 전류 제어를 수행하는 환경으로 변화시켜 고속 운전의 안정적인 제어가 용이하다. 이에 따라 동기 좌표계 전류제어기를 갖는 시스템은 상위 제어기 입장에서 더 높은 대역폭을 가능하게 한다.

동기 좌표계에서 제어를 수행하기 위해서 정지 좌표계에서 세워진 SPMSM 플랜트의 전압방정식을 Park의 변환과 Clarke의 변환을 통해서



동기 좌표계 플랜트 전압방정식으로 표현해야 한다. 동기 좌표계 전압방정식을 구하는 과정은 아래와 같다.

$$V_{dqns}^r = T(\theta_r)V_{abcs} \quad (2.2)$$

$$= T(\theta_r)R_s I_{abcs} + T(\theta_r)L_s \frac{dI_{abcs}}{dt} + T(\theta_r)E \quad (2.3)$$

$$= T(\theta_r)R_s(T^{-1}(\theta_r)I_{dqns}^r) + T(\theta_r)L_s \frac{d(T^{-1}(\theta_r)I_{dqns}^r)}{dt} + T(\theta_r)E \quad (2.4)$$

$$= R_s I_{dqns}^r + L_s \frac{dI_{dqns}^r}{dt} + T(\theta_r)L_s \frac{d(T^{-1}(\theta_r))}{dt} I_{dqns}^r + T(\theta_r)E \quad (2.5)$$

$$\left( T(\theta) = \frac{2}{3} \begin{bmatrix} \cos(\theta_r) & \cos\left(\theta_r - \frac{2}{3}\pi\right) & \cos\left(\theta_r - \frac{4}{3}\pi\right) \\ -\sin(\theta_r) & -\sin\left(\theta_r - \frac{2}{3}\pi\right) & \sin\left(\theta_r - \frac{4}{3}\pi\right) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix}, T(\theta_r) \frac{dT^{-1}(\theta_r)}{dt} = \omega_r \begin{bmatrix} 0 & -1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \right)$$

식 (2.5)의 최종 동기 좌표계 전압방정식을 각각의 좌표계에서 살펴보면 식 (2.6), (2.7)과 같이 표현할 수 있다.

$$V_{ds}^r = R_s I_{ds}^r + L_s \frac{dI_{ds}^r}{dt} - \omega_r L_s I_{qs}^r \quad (2.6)$$

$$V_{qs}^r = R_s I_{qs}^r + L_s \frac{dI_{qs}^r}{dt} + \omega_r L_s I_{ds}^r + \omega_r \lambda_f \quad (2.7)$$

식 (2.6), (2.7)에서 플랜트는 d축과 q축 전류가 서로 결합 되어있기 때문에 통상적인 제어에서는 이를 사전에 측정한 인덕턴스를 이용하여 전향 보상하여 상쇄시킨 후 플랜트를 R과 L만의 직렬 연결인 선형 모델로 만든 뒤 제어가 이득 값을 선정한다. 선정되는 이득 값은 PI제어기에서 생성된 영점이 플랜트의 극점과 상쇄되도록 정해지는데 값은 식 (2.8)와 같다.

$$K_p = \omega_{cc}L_s, K_i = \omega_{cc}R_s \quad (2.8)$$

선정된 이득 값을 통해서 설계된 동기 좌표계 PI 전류제어기를 포함한

제어 블록도는 그림 2.3과 같다. 영점과 극점이 상쇄된 페루프 전달 함수는 (2.9)와 같이 대역폭이  $\omega_{cc}$ 인 1차 저역 필터가 되어 원하는 대역폭의 전류제어 반응성을 얻을 수 있다.

$$\frac{I_{dqsr}}{I_{dqsr}^*} = \frac{\omega_{cc}}{s + \omega_{cc}} \quad (2.9)$$




그림 2.3 PI 전류 제어기 블록도.

## 2.2 인버터 비선형성

플랜트가 2.1.1절에서 다룬 바와 같이 선형 R-L 직렬 회로라 가정하였을 때 PI 제어기를 사용했을 경우 전체 시스템 전달 함수는 1차 저역 필터가 되어 정상상태에서 지령을 오차 없이 추종할 수 있게 된다. 하지만 3상 전압형 인버터를 통해서 전압을 인가하는 경우 위 상 스위치와 아랫 상 스위치가 동시에 켜지는 경우 단락 사고가 발생할 위험이 있기 때문에 이를 방지하기 위해서 스위치 상태가 변하는 사이에 위 상과 아랫 상 모두 꺼져있는 데드 존을 두어야 한다. 데드 존을 유지하는 시간을 데드 타임이라고 하는데 이 데드 타임은 Duty를 변화시켜 의도한 지령 폴 전압과 실제 폴 전압을 다르게 만든다. 이는 제어기 입장에서 플랜트의 전압 외란으로 해석될 수 있는데 상태 변수들의 함수로 표현되는 외란이기에 비선형적 플랜트로 해석할 수 있다. 이러한 비선형성 때문에 1차 저역 필터로 설계하고자 했던 목적에서 어긋나게 되어 실제로 의도했

던 시스템보다 최대 제어 반응성이 제한되거나 정상상태 리플이 발생한다. 본 절에서는 데드 타임이 전압 왜곡을 발생시키는 원리와 전압 왜곡이 어떤 상태 변수에 대한 함수인지 살펴보도록 한다.

### 2.2.1 데드타임과 스위치 온·오프 지연 시간에 의한 전압 왜곡

데드타임은 직접적으로 폴 전압을 그림 2.4와 같이 변화시킨다. 그림 2.4 는 스위치 파형과 그에 의해서 왜곡된 폴 전압을 나타낸 그래프이다.

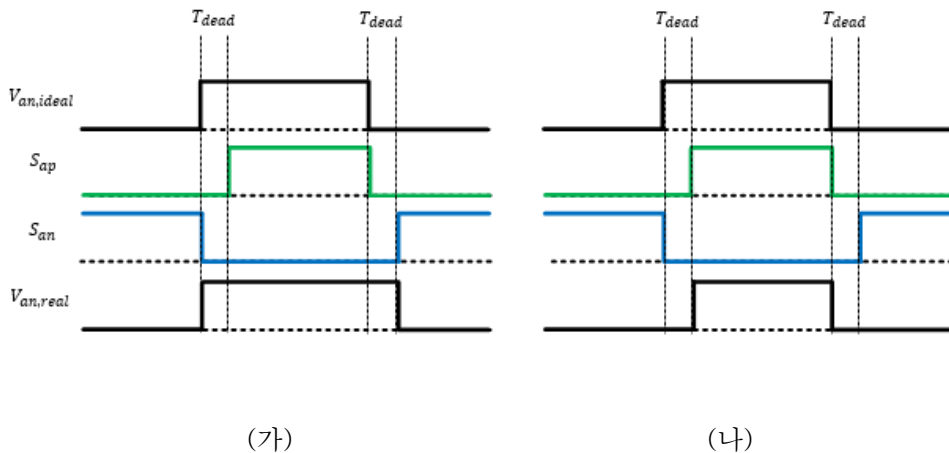


그림 2.4 데드타임에 의한 유효 스위치 파형 (가)전류가 음 방향인 상황  
(나)전류가 양 방향인 상황.

하지만 그림 2.4의  $V_{an,real}$ 에서도 볼 수 있듯이 데드 타임에 의한 Duty 변화가 영향을 끼치는 구간이 있지만 끼치지 않는 구간도 있다. 이는 전류가 해당 스위치 상태 변화 전 스위치를 통하여 흐르는 것과 다이오드를 통하여 흐르는 것에 따라서 달라지게 되는데 세부적인 분석을 위해서는 데드 존에서의 상황을 각 레그의 관점에서 살펴보아야 한다.

데드 타임이란 스위치의 온·오프 상태가 변하는 상황 속에서 주어지는 시간이기 때문에 데드 타임에 의해서 나타나는 효과를 살펴보려면 스위

치 변화의 조합 ( $S_n \rightarrow S_p$ 와  $S_p \rightarrow S_n$ )을 모두 살펴보아야 한다. 또한 전류의 방향에 의해서 스위치로 전류가 흐르지 다이오드로 전류가 흐르지 결정되기 때문에 전류의 방향도 고려해야 한다. 그림 2.5는 스위치 조합과 전류의 방향을 고려한 조합 네 가지를 표현한 그림이다. 다른 상과의 영향은 고려하지 않으며 한 상만의 하프 브릿지로 분석하였다.

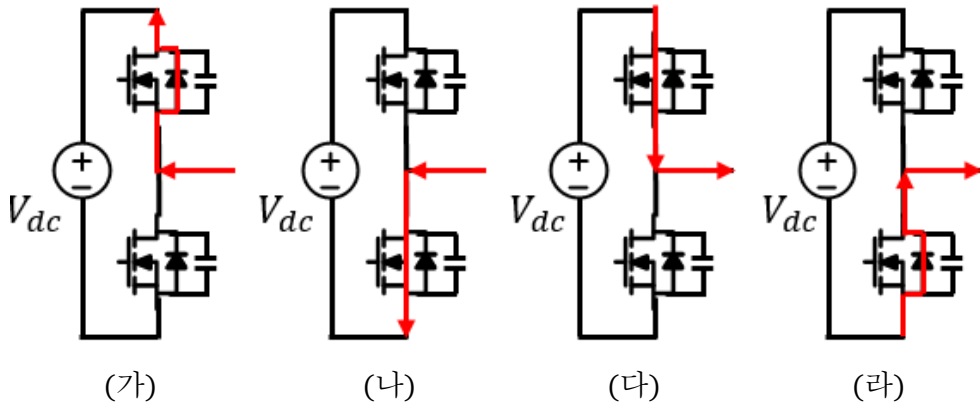


그림 2.5 전류 방향과 스위치 조합에 따른 전류 흐름.

(가)  $i_x < 0, S_{xp} \text{ on}$ , (나)  $i_x < 0, S_{xn} \text{ on}$ , (다)  $i_x > 0, S_{xp} \text{ on}$ , (라)  $i_x > 0, S_{xn} \text{ on}$ .

다이오드를 통해서 전류가 흐르고 있는 동안에는 해당 다이오드와 병렬적으로 연결된 스위치의 상태는 시스템에 영향을 끼치지 못하기 때문에 해당 구간의 데드 타임은 전압 왜곡에 영향을 끼치지 못한다. 따라서 데드 타임이 유효하게 영향을 끼치는 구간은 스위치로 전류가 흐르는 스위치 조합에서 다이오드로 전류가 흐르는 스위치 조합으로 변화하는 순간이다. 이 경우에는 직류단 전압이 스위치를 통하여 이어지는 단락 사고가 일어날 수 있으며 이 구간에서 다이오드가 영향을 끼치지 못하기 때문에 데드존은 유효하다. 그림 2.5의 조합 중에서 살펴보자면 4가지 구간 중 전류가 들어오는 방향의 경우는 (나)  $\rightarrow$  (가)의 변화 순간이며 전류가 나가는 방향의 경우에는 (다)  $\rightarrow$  (라)의 변화 순간이다. 그림 2.6

에는 그림 2.4에서 데드타임이 유효하게 영향을 끼치는 구간을 붉은색으로 표현하였다.

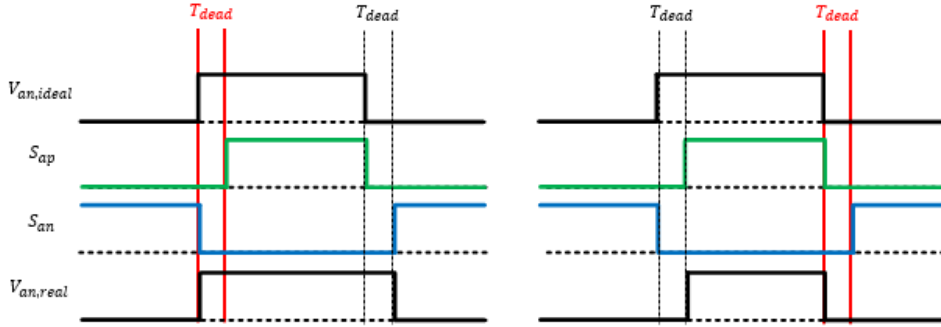


그림 2.6 데드타임이 유효하게 작용하는 구간.

이에 따라 왜곡되는 전압의 양 역시 데드 타임이 유효하게 작용할 때 발생하는데 전류의 방향에 따라서 부호가 결정된다. 크기는 식 (2.10)와 같이 표현할 수 있다.  $T_{on}$ 은 DSP에서 PWM신호가 인가된 시점부터 실제 스위치가 켜질 때까지 시간이고  $T_{off}$ 는 꺼질 때까지 시간이며  $T_s$ 는 스위칭 주기를 나타낸다.

$$V_{dead} = \frac{T_{dead} + T_{on} - T_{off}}{T_s} V_{dc} \quad (2.10)$$

$$\begin{aligned} V_{as,dead} &= \text{sign}(I_a) \cdot V_{dead} \\ V_{bs,dead} &= \text{sign}(I_b) \cdot V_{dead} \\ V_{cs,dead} &= \text{sign}(I_c) \cdot V_{dead} \end{aligned} \quad (2.11)$$

데드타임을 고려하여 식 (2.1)의 전압방정식을 다시 표현해보면 식 (2.12)과 같이 변형해서 나타낼 수 있다.

$$V_{abcs} = R_s I_{abcs} + L_s \frac{dI_{abcs}}{dt} + E + V_{abcs,dead} \quad (2.12)$$

$$\left( V_{absc,dead} = \begin{bmatrix} V_{as,dead} \\ V_{bs,dead} \\ V_{cs,dead} \end{bmatrix} \right)$$

### 2.2.2 기생 캐패시터에 의한 상 전류 크기에 따른 전압 왜곡

데드타임 구간 동안 레그 내 모든 스위치는 꺼져있고 다이오드는 병렬 연결된 기생 캐패시터에 걸려있는 역 전압에 의해 전류가 흐를 수 없는 상황이기 때문에 회로는 직류단 전원과 고립되게 된다. 두 가지 전류 방향 조합 중 음 전류를 예시로 살펴보면 데드 존 상황은 그림 2.7 (가)→(나)로 넘어가는 사이에 존재한다.




그림 2.7 전류가 음인 상태의 스위치 변화 시 기생 캐패시터 전압

폴 전압이 변화하는 시점은 (나)와 같이 윗 상 다이오드가 도통되는 상황인데 이는 스위치에 병렬로 연결되어 다이오드의 역 전압을 가하고 있는 캐패시터가 방전되어야 가능하다. 물론 윗상 스위치가 켜져 직류단 전원과 연결되어 해소되는 방법도 있지만 인덕터에 흐르는 전류에 의하여 캐패시터의 방전에 의해서 데드 존 구간에서 의도했던 시간보다 이르

계 역 전압이 해소되는 경우도 발생할 수 있다.

이 경우에 Duty의 왜곡은 윗 상 다이오드의 역 전압이 해소되는 시간에 따라서 결정되는데 이는 캐패시터에 충전된 전하가 빠지는 속도 즉 데드 존에서 부하 전류의 크기에 의해 결정된다. 따라서 캐패시터 충·방전을 고려한 폴 전압 파형( $V_{an,real}$ )은 그림 2.8과 같이 데드존에서 기울기를 지닌 파형으로 수정되어 표현되고 기울기는 부하 전류에 의해 결정된다. 이 경우 왜곡되는 폴 전압의 양은 삼각형의 면적에 기인하기 때문에 기울기를 결정하는 변수인 데드 존에서의 평균 전류의 함수이다.

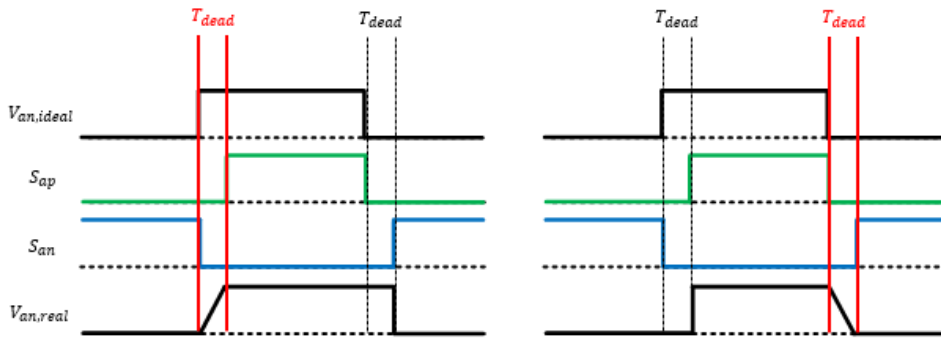


그림 2.8 기생 캐패시터를 고려한 A상 폴전압 파형

전류의 크기에 따라서 데드존에서 달라지는 폴 전압의 기울기는 [19]에서 분석하였는데 측정된 실험 파형은 그림 2.9에서 확인할 수 있다.




그림 2.9 IGBT 음 전류 시 전류 크기에 따른 스위치 on 파형[19].

이러한 전류 크기에 따라서 변화하는 평균 전압을 이용하여 폴 전압 왜곡량을 3상 인덕터를 대상으로 정지 좌표계 d축 전류 제어를 수행하

며 정상상태에서 측정한 결과는 그림 2.10와 같다. 반도체 소자의 차이에 의한 전압 강하의 차이는 미미하다고 가정하였으며 평균적인 전압 강하량은 전동기 상 저항에 포함을 시켜 제거하였다. 측정된 전압 왜곡량은 상 전류의 크기가 작을수록 기울기가 커지고 특정 값 이상이 될 경우 일정 값으로 유지되어 전류가 작은 영역에서 기생 캐패시터의 영향이 두드러지는 것을 확인할 수 있다.




그림 2.10 데드타임에 의한 상 전류에 따라 왜곡되는 폴 전압.



### 2.2.3 PWM 지연에 의한 전압 왜곡[20]

지금까지 분석한 바와 같이 인버터 비선형성에 의하여 발생한 전압 왜곡은 데드 존에서의 상 전류 크기에 따라서 다른 값을 지닌다. 하지만 데드 존이 발생하는 스위치 상태가 변하는 시점에 정확하게 샘플링하는 것은 어렵기 때문에 샘플링 시점에 측정한 전류를 이용하여 왜곡 값을 추정하게 된다. 하지만 DSP로 구현한 제어 시스템은 제어 시간 확보와 AD변환 시간 확보를 위하여 샘플링 시점과 전압 시점 사이 한 샘플 지연이 생긴다. 또한 대표되는 전류 샘플링 시점과 전압 대표 시점의 차이인 0.5 샘플까지 고려하면 총 1.5 샘플의 지연을 지니는데 이는 그림 2.11을 통해서 확인할 수 있다.




그림 2.11 DSP에서 구현된 제어시스템의 샘플링 시점과 전압인가 파형.

2.2.2절까지는 부하 전류의 크기가 충분히 커서 1.5 샘플 사이의 전류 변화가 무시할 정도로 작다는 가정을 사용하여 전류 예측의 필요성에 대하여 언급을 하지 않았지만 영 전류 부근의 작은 전류에서는 데드 존까

지의 전류 변화가 부하 전류 대비 무시할 만큼 작지 않으며 그림 2.10에서 확인할 수 있듯이 전류의 크기가 작을수록 커지는 기울기에 의해서 왜곡되는 전압의 차이가 커진다. 또한 따라서 샘플링 시 전류를 이용해서 보상을 시행할 경우 오히려 잘못된 보상을 통해 제어를 악화시킬 수 있기에 1.5 샘플 뒤의 전류를 예측하여 보상하는 방안이 필요하다. 1.5 샘플 뒤의 전류를 정확하게 예측하기 위해서는 식 (2.14)의 미분방정식을 풀어야 한다.

$$V_{abcs} = R_s I_{abcs} + L_s \frac{dI_{abcs}}{dt} + E \quad (2.13)$$

## 2.3 인버터 비선형성이 전류제어 성능에 끼치는 영향

인버터 비 선형성은 2.2절에서 살펴본 바와 같이 전압 외란의 형태로 전류 제어에 작용한다. 하지만 임의의 외란이 아니라 상태 변수의 함수로 주어지는 외란이기 때문에 플랜트를 비선형적으로 만드는 요소로 분석할 수도 있다. 따라서 선형 제어기인 PI제어기를 사용하는 일반적인 전류 제어기의 경우에 전류 제어기 성능에 제약을 받는다. 본 절에서는 상태 변수의 함수인 인버터 비 선형성에 의한 외란이 전류 제어 성능에 끼치는 영향을 살펴보려고 한다.

### 2.3.1 전류 제어기 반응성 감소[21]

데드타임이 고려된 전압 방정식인 식 (2.12)를 식 (2.14)의 과정을 거쳐서 변환하면 데드타임의 효과가 동기 좌표계에서 설계된 제어 시스템에 어떤 영향을 끼치는지 확인할 수 있다.

$$\begin{aligned} V_{dqns,dead}^r &= T(\theta_r)V_{abcs,dead} \\ &= T(\theta_r)V_{dead} \cdot \text{sign}(T^{-1}(\theta_r)I_{dqns}^r) \end{aligned} \quad (2.14)$$

전류 부호에 따라서 변하는 데드타임의 영향을 근사적으로 확인하기 위해서 기본파 성분만으로 분석할 수 있는데 자세한 과정은 식 (2.15)를 통해서 확인할 수 있다.

$$\begin{aligned} &\text{sign}(T^{-1}(\theta_r)I_{dqns}^r) \\ &= \text{sign} \left( \begin{bmatrix} \cos(\theta_r) & -\sin(\theta_r) & 1 \\ \cos\left(\theta_r - \frac{2}{3}\pi\right) & -\sin\left(\theta_r - \frac{2}{3}\pi\right) & 1 \\ \cos\left(\theta_r - \frac{4}{3}\pi\right) & -\sin\left(\theta_r - \frac{4}{3}\pi\right) & 1 \end{bmatrix} \begin{bmatrix} I_{ds}^r \\ I_{qs}^r \\ I_{ns}^r \end{bmatrix} \right) \end{aligned} \quad (2.15)$$

$$\begin{aligned}
&= \text{sign} \left( \begin{bmatrix} I_{ds}^r \cos(\theta_r) - I_{qs}^r \sin(\theta_r) \\ I_{ds}^r \cos\left(\theta_r - \frac{2}{3}\pi\right) - I_{qs}^r \sin\left(\theta_r - \frac{2}{3}\pi\right) \\ I_{ds}^r \cos\left(\theta_r - \frac{4}{3}\pi\right) - I_{qs}^r \sin\left(\theta_r - \frac{4}{3}\pi\right) \end{bmatrix} \right) \\
&= \text{sign} \left( \begin{bmatrix} \cos(\theta_r + \theta) \\ \cos\left(\theta_r + \theta - \frac{2}{3}\pi\right) \\ \cos\left(\theta_r + \theta - \frac{4}{3}\pi\right) \end{bmatrix} \right) \approx \frac{4}{\pi} \begin{bmatrix} \cos(\omega_r t + \theta) \\ \cos\left(\omega_r t + \theta - \frac{2}{3}\pi\right) \\ \cos\left(\omega_r t + \theta - \frac{4}{3}\pi\right) \end{bmatrix} \\
&\left( \sin(\theta) = \frac{I_{qs}^r}{\sqrt{I_{ds}^r + I_{qs}^r}}, \cos(\theta) = \frac{I_{ds}^r}{\sqrt{I_{ds}^r + I_{qs}^r}} \right)
\end{aligned}$$

이를 통해 나온 근사된 결과를 식 (2.14)에 대입하여 동기 좌표계에서 테드타입에 의한 전압 왜곡을 구하면 식 와 같이 표현될 수 있다.

$$\begin{aligned}
&V_{dqns,dead}^r \\
&= \frac{4}{\pi} \frac{2}{3} V_{dead} \begin{bmatrix} \cos(\theta_r) & \cos\left(\theta_r - \frac{2}{3}\pi\right) & \cos\left(\theta_r - \frac{4}{3}\pi\right) \\ -\sin(\theta_r) & -\sin\left(\theta_r - \frac{2}{3}\pi\right) & \sin\left(\theta_r - \frac{4}{3}\pi\right) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} \cos(\omega_r t + \theta) \\ \cos\left(\omega_r t + \theta - \frac{2}{3}\pi\right) \\ \cos\left(\omega_r t + \theta - \frac{4}{3}\pi\right) \end{bmatrix} \quad (2.16) \\
&= \frac{4}{\pi} V_{dead} \begin{bmatrix} \cos(\theta) \\ \sin(\theta) \\ 0 \end{bmatrix}
\end{aligned}$$


식 (2.16)를 식 (2.12)에 대입한 결과 최종적으로 얻어진 전압방정식은 식 (2.17),(2.18)으로 표현된다.

$$V_{ds}^r = \left( R_s + \frac{4}{\pi} \frac{V_{dead}}{\sqrt{I_{ds}^r + I_{qs}^r}} \right) I_{ds}^r + L_s \frac{dI_{ds}^r}{dt} - \omega_r L_s I_{qs}^r \quad (2.17)$$


$$V_{qs}^r = \left( R_s + \frac{4}{\pi} \frac{V_{dead}}{\sqrt{I_{ds}^r + I_{qs}^r}} \right) I_{qs}^r + L_s \frac{dI_{qs}^r}{dt} + \omega_r L_s I_{ds}^r + \omega_r \lambda_f \quad (2.18)$$

식 (2.17), (2.18)를 살펴보면 등가 저항 값은 전동기 초기 저항 값보다 큰 값으로 느껴지는데 기존의 제어기 이득 선정 기준인 전동기 상 저항과 상 인덕턴스를 기반으로 설정을 할 경우 적분기 이득 값이 작게 설정된 것과 같이 나타나 그림 2.12과 같이 수렴 시간을 오래 걸리도록 만든다.


그림 2.12 는 부하전동기를 500r/min으로 구동하고 있는 상태에서 대상 전동기에 동기 좌표계 d축 전류 제어 지령을 인가했을 때의 전류 제어 파형이다. 전류 제어기 이득값은 두 실험 모두 사전에 측정한 저항과 인덕턴스 값에 비례하게 선정하였고 대역폭은 1kHz로 설정하였다.



(가) 데드타임을 보상하지 않은 제어기



(나) 사다리꼴 보상방법을 통해 데드타임을 보상한 제어기



(다) 데드타임 보상 없이 적분값을 10배 증가시킨 제어기.

그림 2.12 데드타임을 전류제어 반응성에 끼치는 영향.

데드타임을 보상하지 않은 (가)는 데드타임을 보상한 (나)에 비해 수렴 성능이 떨어지는 것을 확인할 수 있다. (다)의 경우는 데드타임 보상을 하지 않은 상태에서 적분기 이득값을 증가시켜 (나)와 같은 반응성을 얻도록 하였다. 적분기 이득값은 원래 저항값에 의해 선정된 경우에 비해 10배 증가되었다. 즉 데드타임을 보상하지 않는 경우 10배 정도로 이득값을 작게 설정한 것과 같이 반응성이 낮아진 것을 확인할 수 있다.

### 2.3.2 6 고조파 전류 리플 성분 증가

PI제어기는 적분기에 오차를 누적함으로써 DC 외란에 의해서 발생하는 오차를 0으로 수렴시킬 수 있다. 하지만 전압 왜곡이 PI제어기가 적분기에 해당 성분을 상쇄시키는 속도보다 빠르게 진동한다면 PI제어기의 잘못된 보상값은 오히려 제어에 악영향을 주게 된다. 데드타임에 의해서 왜곡되는 전압 값은 회전자 회전 속도가 일정하며 부하 각이 고정된 경우에 전류에 대한 함수로 그림 2.10와 같이 표현할 수 있는데 급격하게 변하는 지점은 상 전류가 영에 근접한 부분이기 때문에 각 상 당 전기각 한 주기 내 2번씩 총 6번 발생한다.

이는 그림 2.13을 통해서 확인할 수 있다. 그림 2.13은 500r/min으로 구동하고 있는 상황에서 그림 2.14와 같이 1A 동기 좌표계 d축 전류 제어를 하고 있는 도중의 데드타임에 의해 왜곡되는 폴 전압의 양을 나타낸 파형이다. 이러한 급격한 외란의 변화를 PI제어기가 따라가지 못할 경우 그림 2.14와 같은 동기 좌표계 리플이 발생하게 된다. 화살표를 통하여 급격하게 변하는 지점과 그에 따른 리플을 표시하였다.






그림 2.13 500r/min 구동시 정지좌표계 폴전압 왜란 파형.




그림 2.14 정지좌표계 전압 외란으로 인한 동기좌표계 d축 전류제어 리플 실험 파형.

## 2.4 비선형성을 극복하기 위한 기존 연구의 한계

2.2절의 인버터 비선형성을 극복하기 위한 기존 연구는 오프라인 보상 기법과 온라인 보상 기법 두 가지로 나눌 수 있다. 오프라인 보상 기법의 경우에는 데드 타임이 인가된 회로에서 폴 전압 왜곡 효과를 분석한 모델을 기반으로 보상 하며 온라인 보상 기법의 경우에는 나타나는 왜곡 현상을 기반으로 실시간으로 추정기 변수를 변경해가며 보상한다.

### 2.4.1 오프라인 보상

오프라인 보상 중에서 가장 흔히 쓰이고 있는 방법은 전동기의 정지 상태에서 정지 좌표계 DC 상 전류 제어 시 정상 상태에서 측정한 상 전압 오차 데이터를 이용한다. 상 전압 오차는 상 전압 지령과 측정한 전류로부터 선형 모델을 통해 계산한 추정 상 전압 사이의 차이이다. 이는 그림 2.10와 같이 나타나는데 오프라인 보상 방법들에서는 이 전압 값을 상 전류에 따라 각 상의 폴 전압 지령에 전향 보상한다.

이 데이터를 모두 메모리에 저장하여 직접 인가하는 방법도 있지만 저장 공간의 소요로 인해 사다리꼴, Arctan, Sigmoid 등 다양한 방법으로 피팅하여 보상한다. 이 방법은 회전하지 않는 상황 속에서 큰 전류를 대상으로는 좋은 성능을 보여주지만 영 전류 근처의 전류 예측이 필요한 구간에서는 역 기전력, 전압 지령 등의 정보 없이 전류만의 함수로 보상 값을 결정하였기 때문에 보상 성능이 떨어진다.

그림 2.15는 정상 상태의 전압 오차에 대하여 사다리꼴과 아크탄젠트 보상 식을 피팅한 그래프이다. 아크탄젠트는 거의 완벽하게 데이터에 부합함에도 불구하고 그림 2.17을 통해서 살펴보면 전류가 인버터 정격 대비  $0.04\text{p.u}$  까지는 전류 리플을 줄이지만 저 전류 영역에서는 잘못된 보상값을 만들어 오히려 보상을 하지 않은 상황보다 제어를 악화시킨다. 이는 부하 전류 별로 보상해야 하는 전압을 완벽하게 앞에도 불구하고

데드 타임 구간에서의 전류를 예측하지 못했기 때문이다.







그림 2.15 오프라인 보상을 위한 정상상태 전압 오차에 대한 피팅 그래프.

## 기본 PI 제어기


## 사다리꼴 보상



(가)



(나)



(다)


그림 2.16 사다리꼴 보상방법의 저 전류 영역에서의 한계.

(가) 2A(0.04p.u.), (나) 1A(0.02p.u.), (다) 0.5A(0.01p.u.).


## 기본 PI 제어기




## 아크탄젠트 보상



(가)



(나)



(다)

그림 2.17 아크탄젠트 보상 방법의 저 전류 영역에서의 한계.

(가) 2A(0.04p.u.), (나) 1A(0.02p.u.), (다) 0.5A(0.01p.u)

또한 전류를 예측하여 예측된 전압 왜곡값을 보상하는 연구[22]도 있는데 이 연구들은 모델의 선형성을 가정한 이후에 예측을 하였기 때문에 부정확성을 지니고 있으며 평균 전류를 구하는 과정 속에서도 미분방정식을 풀어 초월 함수 형태의 해를 이용해야 하지만 연산 시간의 제약으로 인해 전류의 변화가 선형적이라는 가정하에 계산하였다. 이러한 예측 방법은 영 전류 클램핑 효과에 의한 비선형적인 전류 증가와 캐패시터와 인덕터에 의하여 초월함수 개형으로 증가하는 형태의 전류를 온전히 예측할 수 없다. 또한 전류 센서의 오차나 온도에 의해서 실시간으로 변하는 저항에 대한 정보가 담겨있지 않은 오프라인에서 정상상태에서 측정된 데이터를 이용하여 보상하기 때문에 이러한 요인들에 의해 발생하는 오차를 보정할 수 없다.

#### 2.4.2 온라인 보상

온라인 보상은 오프라인 보상방법의 한계점을 극복하기 위하여 반복학습 제어 혹은 인공신경망 학습 제어 등의 방법을 이용하였다.

[1-3]는 외란 관측기를 이용하여 온라인으로 데드타임에 의한 전압 외란을 추정 한 뒤에 이를 이용하여 상쇄시키는 연구이다. 외란 관측기는 상태방정식을 통해서 설계되는데 상태방정식은 식 (2.6), (2.7)의 선형 모델을 기반으로 이루어져 있다. 따라서 모델 변수 오차 혹은 모델 구조의 오차에 취약하며 관측기의 대역폭이 관측기 이득 값에 따라서 선정되는데 속도에 따라서 상쇄해야 하는 리플의 주파수가 달라지기 때문에 이득값 선정이 어렵다는 문제를 지니고 있다.

[5]는 반복 학습 제어기를 이용하여 데드타임에 의해서 발생하는 전압 오차를 동기 좌표계 전압을 통해 보상하는 연구이다. 보상은 동기좌표계의 전류 오차를 최소로 하는 것을 목표로 하며 반복 제어기의 보상 값을

결정하는 입력 변수는 회전자 위치와 동기좌표계 전류 지령각을 더한 각도를 사용한다.

$$\Phi = \gamma + \theta_r$$

$$\gamma = \sin^{-1} \left( \frac{i_q^*}{\sqrt{i_d^{*2} + i_q^{*2}}} \right), \theta_r : \text{회전자 위치} \quad (2.19)$$

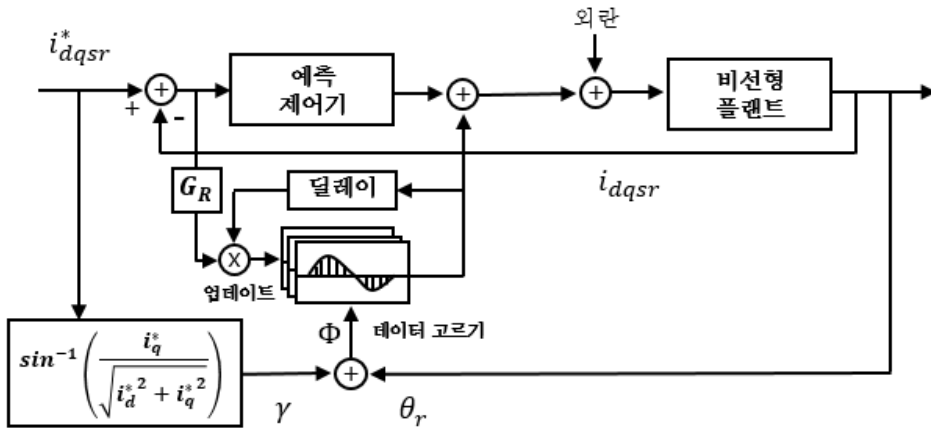


그림 2.18 반복제어를 이용한 인버터 비선형성 상쇄 알고리즘 블록도 [5].

이 방법은 반복제어를 사용하였기 때문에 각도 별로 보상 값을 저장하는 메모리가 필요하기 때문에 많은 메모리를 필요로 한다. 또한 운전 점 마다 달라지는 보상 값에 대해서 부하 각 만을 입력 변수로 삼았기 때문에 운전 속도나 전류 크기가 달라질 경우의 달라지는 보상 값에 대한 고려가 되어있지 않다. 따라서 운전 점이 달라질 때 잘못된 보상을 하게 되고 수렴하기까지 오랜 시간이 걸리며 입력 변수로 선정되지 않은 변화에 대해서 오차를 영으로 만들기 위해서는 테이블이 계속 업데이트가 되어야 하는데 테이블을 업데이트하는 속도( $G_R$ )보다 빠르게 변화하는 고려되지 않은 입력 변수에 대해서 이 방식을 사용할 경우 공진이 발생

하여 제어 안정성을 악화시킬 수 있다.

[10]는 데드 타임에 의한 전압 왜곡의 영향이 동기 좌표계에서 6고조파 인리플을 발생시킨다는 점에서 착안하여 인공신경망을 이용해서 동기 좌표계 6고조파 성분을 추출해 내어 보상한 연구이다. 전체 구조는 그림 2.19와 같으며 인공신경망은 추출한 6고조파 전류를 이용해서 보상값을 구하는데 이용된다. 인공신경망의 구조는 은닉 뉴런이 없는 구조로 그림 2.20와 같이 구성되어있으며 각각의 변수는 전류 오차가 0이 되도록 학습된다.

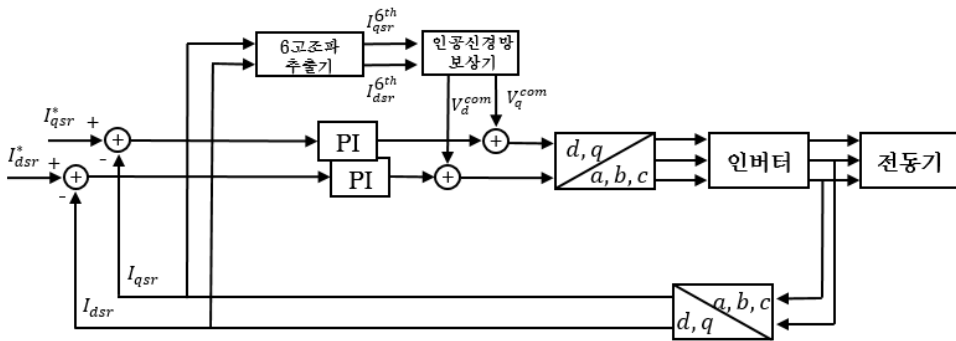


그림 2.19 인공신경망을 이용한 인버터 비선형성 보상 알고리즘 블록도.




그림 2.20 ADALINE 인공신경망 보상기.



이 구조 역시 입력 변수가 동기 좌표계 6고조파 성분만이 들어가 있기 때문에 반복제어기와 마찬가지로 과도상태에서 보상할 수 없으며 6고조파 사인 함수의 합으로 보상치를 결정하기 때문에 정확하게 사인함수가 아닌 형태의 외란을 보상할 수 없게 되어 정확하게 리플을 상쇄할 수 없게 된다. 또한 인공신경망을 사용하였지만 은닉 뉴런과 활성화 함수를 사용하지 않았기 때문에 온라인 학습을 진행하였다고 하더라도 영전류 근처에서 전류를 예측하기 위한 비선형성을 학습을 통해 얻어낼 수 없다. 논문에서 제시한 실험 결과 또한 정격 부하 인가를 통해 전류가 큰 상황 속에서 이루어 졌기 때문에 상대적으로 영전류 부근을 지나는 구간이 짧아 낮은 전류에서 캐패시터에 의한 효과와 영전류 클램핑에 대한 보상이 제대로 이루어 졌다고 보기 어렵다.

## 제 3 장 제어분야에서의 딥 러닝

딥 러닝이란 구조적 자유도를 가진 인공신경망에 자동으로 시스템의 변수를 최적화하는 알고리즘인 학습의 개념을 적용한 분야이다. 기존의 시스템은 각 시스템이 가지고 있는 구조적 특징이 있어 제한된 구조 안에서 변수를 변동시키며 적절한 시스템을 얻어내는 반면 인공신경망은 구조의 자유도를 지니고 있어 구조가 알려져 있지 않은 다양한 비선형 시스템을 표현할 수 있다. 하지만 이는 인공신경망의 구조적 자유도를 주는 변수를 최적의 값으로 설정하였을 경우에만 가능하지만 변수의 양과 활성화 함수의 비선형성에 의해 시스템 내의 각각의 변수가 전체 시스템에서 어떤 역할을 하는지 알고 사용자가 설정하는 것은 어렵다. 따라서 자동으로 변수를 찾아주는 알고리즘을 사용하여 시스템을 최적화하는데 이를 학습이라 한다. 3.1절에서는 인공신경망의 구조를 다루며 비선형 함수를 모의할 수 있는 원리를 살펴볼 것이다. 3.2절에서는 인공신경망의 학습에 대해서 다룬다. 학습의 기본 원리는 변수 최적화 알고리즘의 일부이며 학습 데이터 선정에서부터 학습 구조 등에 대해서 본 장에서 살펴본다.

### 3.1 인공신경망 구조

인공신경망이란 그림 3.1과 같은 MIMO(Multi Input Multi Output) 시스템의 특정 구조를 뜻하는 용어로서 다수의 입력신호를 받아 입력층, 은닉층, 출력층을 거쳐서 다수의 출력 신호를 내보내는 시스템이다.




그림 3.1 인공신경망 구조.

### 3.1.1 구성요소

인공신경망의 첫 번째 구성요소는 뉴런이다. 뉴런이란 인체의 신경망에서 전기 신호를 전달하는 매개체이며 인공신경망에도 인체의 신경망의 뉴런에 대응되는 뉴런이 존재한다. 인공신경망에서의 뉴런을 신경망에서 처럼 신호를 전달하는 매개체로 볼 수도 있지만 구현의 관점에서 보면 특점 시점에서 해당 신호를 저장하는 데이터로 보는 것이 더 적합하다.

다음 구성요소는 변수다. 그림 3.2는 그림 3.1의 전체 인공신경망 내에서 한 뉴런에서 다음 뉴런으로 신호를 전달할 때의 최소 신호 전달 단위를 표현한 블럭도이다. 신호를 전달할 때는 이전 뉴런에서 나온 데이터에 **weight**가 곱해지고 **bias**가 더해져서 나온 데이터가 **threshold** 값을 넘어 활성화가 되어야만 다음 뉴런으로 전달될 수 있다. 인공신경망의 변수란 이 과정에서의 **weight**와 **bias**를 의미한다. 변수의 값이 적절히 설정되어야 매 상태(State)에서 활성화되는 뉴런이 의도한 대로 결정되기

때문에 변수 선정을 올바르게 하는 것은 중요하다.




그림 3.2 인공신경망의 신호 전달 블록도

다음 구성요소는 활성화 함수이다. 활성화 함수는 특정 뉴런으로부터 오는 신호를 차단하여 입력 변수의 상태에 따라 시스템이 변하도록 만들어 준다.





그림 3.3 입력함수의 상태에 따른 인공신경망의 활성화

대표적인 활성화 함수는 그림 3.4에 나타난 바와 같이 ReLU (Retified Linear Unit), Tansig, Sigmoid이며 각 함수에 대한 식은 식 (3.1),(3.3)과 같다.



(가)

(나)

(다)

그림 3.4 활성화함수 (가) ReLU, (나) Tansig, (다) Sigmoid.

$$\text{ReLU}(x) = \max(0, x) \quad (3.1)$$

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-kx}} \quad (3.2)$$

$$\text{Tansig}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.3)$$

ReLU는 forward 연산 양이 적고 학습 시 사용되는 기울기 값이 입출력 변수 값과 독립적이기 때문에 연산과 학습이 빠르다는 장점이 있어 가장 많이 쓰이고 있다. 하지만 Sigmoid와 Tansig는 초월 함수로 표현되어있기 때문에 특정 비선형 함수를 표현하는데 있어서 적은 뉴런이 소요된다. 따라서 시스템에 따라서 메모리와 연산량을 고려하여 적합한 활성화 함수를 선정하여야 한다.

### 3.1.2 활성화를 통한 비선형 함수 모의

뉴런의 활성화는 해당 뉴런에 들어온 신호의 크기에 따라 결정이 되며 해당 시점의 각 뉴런의 신호를 결정하는 것은 입력 뉴런으로 들어오는 신호의 상태(State)이다. 따라서 각 상태마다 활성화 되는 뉴런이 그림 3.3과 같이 달라지고 각 은닉 층 내부 뉴런 개수를  $n_i$  라고 할 때 은닉 층마다  $2^{n_i}$  개의 시스템을 가변할 수 있는 가능성이 존재한다. 또한 각 층별로 뉴런의 활성화는 서로 독립적이기 때문에 총  $m$ 개의 은닉 층이 있다고 할 때 전체 가변 시스템 조합의 수는  $\prod_{i=1}^m 2^{n_i}$  개이다. 인공신경망은 이처럼 매 상태마다 시스템을 가변하며 가능한 조합 중에서 적합한 한가지 조합을 선택하여 비선형적인 시스템을 모의할 수 있게 된다.

그림 3.5는 활성화 함수 ReLU를 이용한 경우 은닉 뉴런 개수에 따라서 인공신경망이 비선형함수를 모의하는 성능을 비교한 결과이다. 사용된 활성화 함수는 ReLU이기에 선형 시스템들의 선형 보간으로 각 입력 변수에 대한 시스템이 결정된다. 그림 3.5(가)는 은닉 뉴런이 1개이기에 상태에 따라서 2가지 조합이 있을 수 있고 그에 따라서 기울기가 다른 두 개의 직선을 통해서 시스템을 모의할 수 밖에 없다. 은닉 뉴런의 개수가 10개, 50개로 개수가 늘어날수록 더욱 부드럽게 비선형 함수를 모의할 수 있는 것을 (나), (다)를 통해서 확인할 수 있다.




그림 3.5 ReLU 활성화 함수를 사용한 경우 은닉 뉴런 수에 따른 비선형 모의성능 그래프.

(가) 은닉 뉴런 1개, (나) 은닉 뉴런 5개, (다) 은닉 뉴런 10개.

은닉뉴런의 수가 많아질수록 이론상 모의하고자 하는 시스템에 더 가까워져야 하지만 학습해야 할 변수의 개수가 많아지기 때문에 최적 조합을 찾는 것이 어려워 너무 많아 질 경우 더 안 좋은 학습 결과를 나타낼 수 있다. 따라서 적절한 숫자의 뉴런을 선정하는 것이 중요하다. 그림 3.6은 MATLAB 내부 학습 함수를 이용하여 은닉 뉴런의 수를 변화시키며 5회의 서로 다른 랜덤한 시작점으로부터 학습 결과 중 가장 낮은 오차 값을 비교한 그래프이다.






그림 3.6 은닉뉴런 수에 따른 모의 성능 변화.

활성화 함수는 3.1.1절에서 언급한 바와 같이 활성화되는 뉴런의 조합을 선택하는 기능 외에도 어떤 활성화 함수를 선택하는지에 따라서 비선형 함수를 모의하는 성능이 달라진다. ReLU를 이용하여 활성화 할 경우 활성화 함수는 비활성화/활성화의 역할만 할 뿐 입력신호를 변형시키지 않고 부분 선형화의 원리를 이용해서만 비선형 함수를 모의한다. 하지만 Tansig 함수를 쓸 경우에는 삼각함수 조합을 통해서 비선형 함수를 모의하며 Sigmoid 함수를 쓸 경우에는 Sigmoid 조합을 통해서 비선형 함수를 모의하게 된다. 그림 3.7은 ReLU와 Sigmoid를 은닉 뉴런의 수를 변화시켜가며 비선형함수를 모의하는 성능을 비교한 모의실험 결과이다. Sigmoid를 사용한 경우 같은 수의 뉴런을 사용하였을 때 비선형 함수를 더 유사하게 모의한 것을 확인할 수 있다.







(가)



(나)



(다)



(라)

그림 3.7 활성화 함수의 종류에 따른 인공신경망 비교.

(가) ReLU 은닉뉴런 1개, (나) ReLU 은닉뉴런 5개, (다) Sigmoid 은닉뉴런 1개, (라) Sigmoid 은닉뉴런 1개.

이처럼 인공신경망은 활성화 원리에 따라서 상태마다 최적의 조합을 선택하여 다양한 비선형 시스템을 모의할 수 있다. 하지만 인공신경망은 비선형 함수인 활성화 함수를 포함하고 있으며 선정해야 하는 변수가 매우 많기 때문에 기존의 설계 방식을 통하여 모든 변수를 적절히 선택하는 것은 어렵다. 따라서 자동으로 적합한 변수를 찾는 것이 중요한데 이를 가능하게 해주는 것이 학습이다.

## 3.2 인공신경망 학습

인공신경망의 학습이란 인공신경망이 원하는 시스템과 동일하게 동작하도록 내부 변수(weight & bias)를 최적화 하는 과정이다. 인공 신경망은 구조상 어떤 시불변 비선형 함수도 모의할 수 있지만 이는 변수가 적절히 선정된 상황 하이기 때문에 학습은 인공 신경망 분야에서 매우 중요하다. 학습의 기본 구조는 그림 3.8과 같이 MRAS와 동일한 구조이며 기준 시스템과 대상 시스템 그리고 손실 값으로 구성되어있다.

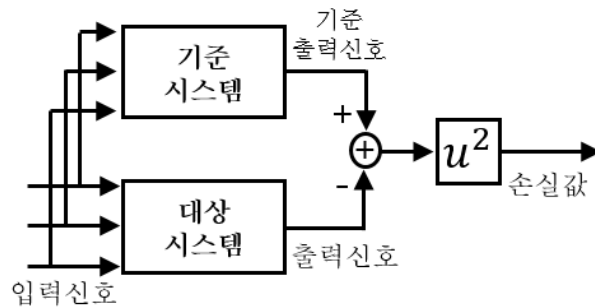


그림 3.8 변수 최적화 알고리즘 블록도.

인공신경망의 설계 및 학습 절차는 다음 세가지 단계로 나뉘어 진행된다. 1) 성능척도 선정 2) 학습 방법 선정 3) 학습 알고리즘 선정.

### 3.2.1 성능 척도 선정

인공신경망이 원하는 시스템을 모의하도록 하기 위해서는 성능 척도가 중요하다. 성능 척도는 그림 3.8에서와 같이 이상적인 데이터와 실제 데이터 사이의 차이의 L2 norm 혹은 평균 제곱 오차(MSE, Mean square error)으로 일반적으로 설정되는데 이를 손실 값이라고 부른다. 성능 척도의 선정 기준은 인공신경망이 모의하고자 하는 시스템이 사전에 정의되어 집적 입·출력 데이터에 접근 가능한 경우와 가상의 최적 시스템인

경우여서 정의되지 않아 직접 접근하지 못하는 경우 두 가지 경우로 나눌 수 있다. 전자의 예시는 각 추정기, 역 플랜트 추정기가 있고[23] 후자의 경우에는 인공신경망 제어기 혹은 제어기 이득 궤적 선정기 등이 있다[24].

인공신경망이 모의하고자 하는 시스템의 입출력에 접근 가능한 경우에는 손실 값을 모의하고자 하는 시스템의 출력과 인공신경망의 출력의 차이의 평균 제곱 오차를 성능 척도로 삼는다. 그림 3.9의 예시는 플랜트의 비선형성을 인공신경망이 모의하도록 하는 예시이며 상태에 따라서 플랜트의 출력을 예측하는 예측제어기나 비선형성을 상쇄하기 위한 목적으로 사용되는 구조이다[23]. 이 경우에 대상 시스템은 인공 신경망이고 기준 시스템은 인공신경망이 모의하고자 하는 시스템이다.

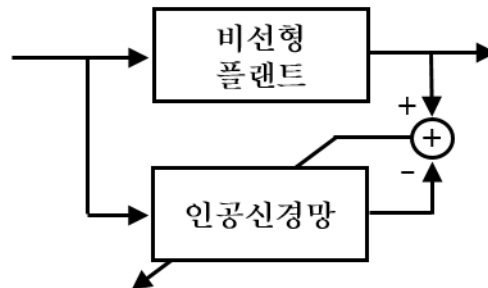


그림 3.9 비선형 플랜트 모의 인공신경망 학습 블록도

다음으로는 인공신경망이 모의하고자 하는 시스템의 실체가 명확하지 않아 입출력 데이터 셋에 직접 접근할 수 없는 경우이다. 이러한 시스템의 예시로는 신경망 PID제어기가 있다[24].

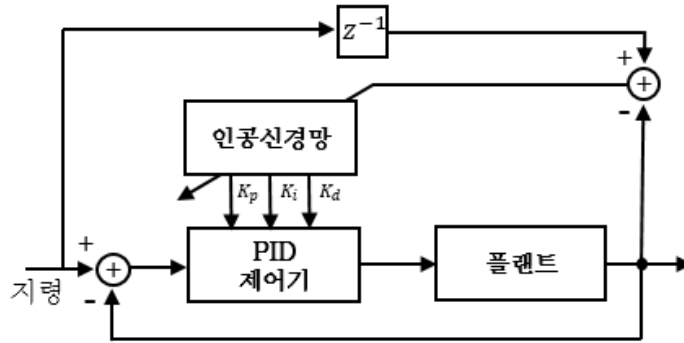


그림 3.10 인공신경망 PID 이득값 제적 결정기 학습 블록도.

[24]에서 인공신경망이 모의하고자 하는 시스템은 상태 변수에 따라서 매 time step에서 최적의 PID 이득 값을 출력하는 시스템이다. 최적의 PID 이득 제적은 알려져 있지 않기 때문에 이 경우에 인공신경망이 모의하고자 하는 시스템은 가상 시스템이다. 따라서 최적 시스템의 출력은 접근 불가능하다. 학습을 통해서 간접적으로 가상의 최적의 시스템을 인공신경망이 모의하도록 하는 것이 본 구조에서 학습의 목적이다. 이 경우에는 성능 척도를 상태 변수 중 하나인 지령 변수 값과 지령 변수에 해당하는 상태 변수 값과의 차이의 평균 제곱 오차인 손실 값의 크기로 삼는다. 최소 손실 값을 목표로 대상 시스템의 변수를 찾는 과정을 통해 그 구성 요소인 인공 신경망의 변수도 얻어낸다.

이 경우에는 기준 시스템은 직접 모의하고자 하는 시스템이 아니라 현실적으로 가능한 지령과 측정값 사이의 관계가 되고 대상시스템은 인공신경망과 플랜트를 포함한 시스템이다. MRAS에서는 1차 저역 필터를 기준 시스템으로 삼았지만 [24]에서는 한 샘플 지연 시스템을 기준 시스템으로 삼았다.

### 3.2.2 학습 방법 선정

학습 방법은 학습할 데이터 추출과 학습의 동시성에 따라서 사전에 추출된 데이터를 이용하는 오프라인 학습과 실시간으로 추출되는 데이터를 이용한 온라인 학습으로 나눌 수 있다. 오프라인 학습은 추출된 전체 데이터 셋에 대해서 손실 값의 총 합을 가장 작게 만드는 변수를 찾는 학습 방법이고 온라인 학습이란 특정 **time step**에서의 손실 값을 가장 작게 만드는 방향으로 변수를 매 **time step**마다 업데이트하는 학습방법을 의미한다.

오프라인 학습은 두 가지 절차로 나뉘는데 첫 번째 절차는 데이터 추출이고 두 번째는 변수 업데이트이다. 데이터 추출 구조는 그림 3.11과 같으며 임의의 입력신호를 기준 시스템에 인가하여 출력되는 출력 신호를 인가하였던 인가 신호와 함께 저장공간에 저장한다.




그림 3.11 오프라인 학습의 학습 데이터 추출 블록도.

오프라인 학습은 추출된 데이터만을 이용하여 대상 시스템을 업데이트 하기 때문에 데이터 추출 과정은 매우 중요하다. 왜냐하면 데이터 추출 시 보여진 기준 시스템에 대해서만 대상 시스템이 동일하게 모의되기 때문이다. 따라서 기준 시스템을 통해서 입출력 데이터를 추출 시 입력 신호는 기준 시스템의 자유도 이상의 자유도를 가진 신호를 인가하여 출력 데이터를 추출해야 하며 대상 시스템에서 사용될 전체 운전 영역 (입력

신호 크기, 입력 신호 주파수 영역)을 포함하는 광 범위의 데이터를 이용하여 출력 데이터를 추출해야 한다.

두 번째 절차는 변수 업데이트이며 구조는 그림 3.12와 같이 사전에 저장된 기준 시스템에서 얻어진 입출력 데이터를 이용한다. 데이터 추출 시 사용한 데이터와 동일한 입력 신호를 대상 시스템에 인가하여 출력된 출력 신호와 저장된 기준 출력 신호의 차이로 계산된 손실 값을 이용하여 3.2.3절에서 다룬 변수 최적화 알고리즘을 사용하여 데이터 쌍 전체에 대해서 대상시스템을 한 번씩 업데이트 한다. 여기서 성능 척도는 데이터 전체 쌍에 대한 손실 값의 누적 합이다.

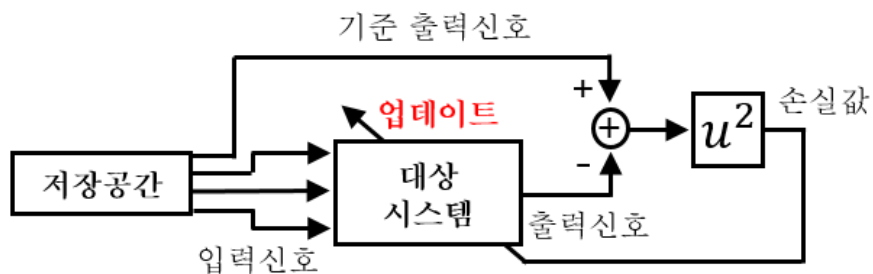


그림 3.12 오프라인 학습의 변수 업데이트 블록도.

온라인 학습은 실시간으로 학습이 이루어 지는 것이기 때문에 오프라인 학습과 달리 학습 절차가 나뉘지 않는다. 또한 적응제어기에서와 같이 실시간으로 변하는 플랜트에 대해서 학습 속도가 충분히 빠르다면 기준 시스템을 실시간으로 모의할 수 있다. 때문에 오프라인 학습과 같이 플랜트의 변화를 모두 감지할 수 있는 신호를 입력 변수로 넣어주지 못한 경우에도 실시간으로 주어진 입력 변수들 만을 이용해서 대상 시스템을 업데이트 하여 순간의 기준 시스템을 모의할 수 있다.

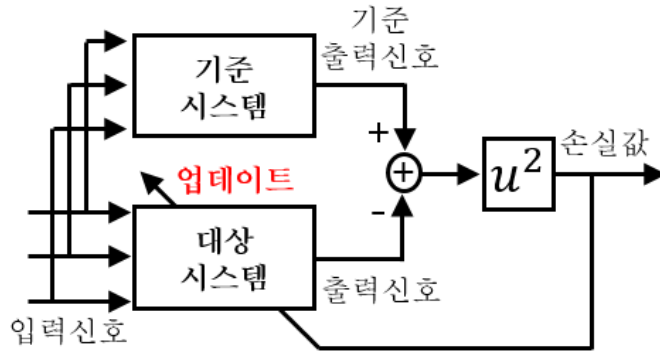


그림 3.13 온라인 학습의 변수 업데이트 블록도.

하지만 온라인 학습의 경우 피드백 루프가 있기 때문에 학습 속도보다 빠르게 변화하는 플랜트에 대해서 공진이 생기거나 시스템이 발산할 수 있기 때문에 안정도가 보장되는 영역 내에서 사용하여야 한다. 여기서 성능 척도는 순간의 데이터에 대한 손실 값이다.

두 학습방법의 장단점을 요약하자면 오프라인 학습의 경우에는 연산 시간의 제약이 없어서 시간이 많이 소요되는 전역 탐색 알고리즘을 사용할 수 있고 학습 도중에 불안정한 영역을 지나는 것에 대한 제약이 없는 장점이 있지만 대상 시스템의 변화에 대처할 수 있는 입력 변수가 인공 신경망의 입력 변수로 할당되지 않은 경우 평균적으로 가장 손실 값을 최소화 시키는 변수로 수렴하기 때문에 손실 값을 줄이는데 한계가 있다. 반면 온라인 학습은 매 **time step**마다 인공 신경망 연산과 학습이 모두 이루어져야 하기 때문에 연산 시간의 제약이 있어 연산 부담이 적은 지역 탐색 알고리즘을 주로 사용하고 학습 도중에 불안정한 영역을 지나지 말아야 하기 때문에 초기 변수 선정이 매우 중요하다. 하지만 이 경우에는 입력 변수가 대상 시스템의 변화를 감지할 수 없는 경우에도 학습 속도가 대상시스템의 변화보다 충분히 빠른 경우 오차가 0이 되도록 모의하는 것이 가능하다. 따라서 학습하고자 하는 시스템에 맞추어 알맞은

학습 방법을 선정하여야 한다.

### 3.2.3 학습 알고리즘 선정

인공신경망에서 학습이란 3.2.1절에서 선정한 성능 척도가 최소가 되도록 하는 최적의 변수를 찾는 과정이기 때문에 변수 최적화 알고리즘인 Least Square Method나 Gradient Descent Method가 사용된다. 하지만 최근의 인공신경망 구조의 복잡성과 활성화 함수의 비선형성의 도입으로 인하여 역 행렬을 계산하여야 하는 Least Square Method보다 순간의 변수 변화 대비 손실 값 변화인 Sensitivity를 이용하는 Gradient Descent Method에 기반한 알고리즘이 주로 사용되고 있다.

Sensitivity란 손실 값을 각 변수로 편 미분한 값으로 식 (3.4)와 같이 표현되는 값이다. 즉 Sensitivity란 변수 영역에서 손실 함수를 나타냈을 때 특정 변수 조합에서의 순간 기울기를 의미한다.

$$S(\text{sensitivity}) = \frac{\partial J}{\partial \theta} \quad (3.4)$$

따라서 sensitivity의 방향과 반대 방향으로 각 변수를 변화시킨다면 점점 손실 값이 작아지도록 변수를 변동시킬 수 있고 이 과정을 반복하다 보면 최적의 변수를 찾을 수 있게 된다. 이 경우 1차 기울기를 이용할 수도 있고 2차 기울기를 이용할 수도 있는데 1차 기울기를 이용한 알고리즘을 Gradient Descent Method라고 부른다.

$$J = e^2 \quad (3.5)$$

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} \quad (3.6)$$

( $\gamma$  : learning rate,  $J$  : loss function,  $\frac{\partial J}{\partial \theta}$  : sensitiveity derivative)

한 예로 이러한 원리를 이용하면 제어기 변수를 최적화하는데 이용할



수 있다. 이 경우에 손실 값은 제어 대상인 측정 값과 지령 값의 차의 L2 norm이 되며 최적화할 변수는 제어기 변수다. 오프라인 학습에서 Gradient Descent Method를 적용할 경우에는 매 time step에서의 sensitivity값을 모두 누적한 뒤 전체 학습 데이터 셋에 대한 sensitivity 누적 값의 평균값을 한번에 적용하여 변수를 업데이트 한다. 온라인 학습에서 Gradient Descent를 적용할 때에는 매 time step에서 발생한 변수의 변화를 바로 적용하여 변수를 업데이트를 하고 업데이트 된 변수로 다음 time step에서의 제어를 수행하게 된다.

그림 3.14 은 SPMSM 속도 PI 제어기를 특정 지령 궤적에 대해 운전하였을 때 각 변수 조합에 대한 손실 값을 나타낸 그래프이다. X 표시되어있는 지점이 최소 손실을 가져오는 변수 쌍의 위치이다.






그림 3.15 PI 속도제어기 제어기 이득에 따른 손실 평면.

Gradient Descent 알고리즘을 통해서 오프라인으로 학습을 진행한 경우 변수의 변화는 그림 3.16의 좌측 그래프처럼 손실 평면 위 붉은색 선을 따라 이동한다. 우측 파형은 이동한 변수에서 구동했을 경우의 모의 학


습 결과이다. Gradient Descent 알고리즘을 통해서 변수는 최소 손실 점인  $x$ 을 찾아가는 것을 확인함과 더불어 모의 실험에서의 속도 응답성이 향상됨과 오버 슈트가 감소하는 것을 확인할 수 있다.




(가)



(나)



(다)



(라)

그림 3.16 Gradient Descent를 적용한 속도 PI 제어기 학습과정.

식 (3.6)에서 learning rate 변수를 통하여 매 업데이트 회 당 변수를 변동시키는 속도를 조절할 수 있다. Learning rate가 클 수록 빠르게 최적 점에 다다르지만 최적 점 근처에서 수렴하지 못하고 진동하거나 최적 점을 벗어나 발산할 수 있다. 이를 해결하기 위해서 개선된 알고리즘이 adaptive learning rate를 적용한 Adadelta이다[25]. Adadelta는 시작 시점부터 현재까지의 기울기 값의 L2 norm을 기존 learning rate에서 나눈 값을 식 (3.7)에서처럼 새로운 learning rate로 사용한다. 이를 적용하게 되면 처음엔 큰 learning rate값을 사용하여 빠른 수렴을 의도하고 학습이 진행될수록 learning rate를 작게 만들어 정교하게 최소 지점을 찾을 수 있다.

$$\frac{d\theta}{dt} = -\frac{\gamma g_t}{\sqrt{\sum_{r=1}^t g_r}} \quad (3.7)$$

$$g_t = \frac{\partial J_t}{\partial \theta} \quad (3.8)$$

Gradient Descent 알고리즘의 경우에는 Sensitivity라는 기울기 값을 기준으로 최적 점을 찾기 때문에 부분 최소 점에서 벗어날 수 없다. 이 문제를 해결하기 위해서 learning rate에 관성 개념을 적용한다[26]. (3.9)와 같이 이전 업데이트한 기울기를 현재 sensitivity를 이용한 값에 가중치를 곱해서 더해주는 것인데 이를 이용하면 부분 극소 점이 나타났을 때 지금까지 누적된 기울기 값인 관성치가 있기 때문에 부분 극소 점을 벗어날 수 있다.

$$\frac{d\theta_t}{dt} = \alpha \frac{d\theta_{t-1}}{dt} + \gamma \frac{\partial J_t}{\partial \theta_t} \quad (3.9)$$

하지만 이 방법의 단점은 전역 최적점에 도달한 경우에도 바로 수렴하지 않고 관성 가중치에 의해서 다른 점으로 벗어나기 때문에 수렴 속도

가 느릴 수 있다.

Gradient Descent 알고리즘의 두 가지 단점을 해결하는 방법인 Adaptive learning rate와 관성 개념을 모두 적용한 것이 Adam[27]이며 연산 시간이 기본 Gradient Descent보다 오래 소요되기 때문에 오프라인 학습에 주로 쓰인다.

## 제 4 장 딥 러닝을 이용한 인버터 비선형성 보상

4장에서는 3장에서 언급한 인공신경망의 높은 자유도를 이용해서 2장에서 언급한 인버터 비선형성에 의한 전압 외란 모델을 직접 모의하는 방법을 제안한다. 인공신경망이 데드타임 시 발생하는 인버터의 폴 전압 왜곡량을 모의하기 위해서는 데드타임 구간의 평균 전류를 예측해야 하며 예측된 전류를 기반으로 기생 캐패시터 효과를 고려한 전압 왜곡량을 모의할 수 있어야 한다. 4.1절에서는 인공신경망을 어떤 용도로 사용하는지에 대해서 전체 구조 블록도를 살펴볼 것이고 4.2절에서는 제안하는 인공신경망 설계 및 학습 방법에 대해서 다룰 것이다. 인공신경망을 설계 시에는 전류 예측, 인버터 전압 왜곡과 연관된 변수를 입력 변수로 할당하여 다양한 조건하에서 인버터 비선형성을 모의할 수 있도록 할 것이며 학습 시에는 오프라인과 온라인 학습으로 나누어 각각의 장단점을 보완하는 학습방법을 제시하고자 한다.

### 4.1 인공신경망을 통한 플랜트의 선형화

인공신경망은 3.1절에서 살펴본 바와 같이 비선형함수를 모의할 수 있는 성질 덕분에 [28]에서는 플랜트의 비선형성과 외란을 상쇄하여 플랜트를 기준 모델에 피팅하는 용도로 사용하였다. 해당 연구에서는 예측제어기를 사용하기 위해서 모델을 정확하게 알아야 하는데 이를 위하여 플랜트를 기준 선형화 모델에 피팅한 후에 피팅된 모델을 예측제어기의 플랜트 모델로 사용하였다. 그림 4.1는 인공신경망을 이용하여 플랜트를 선형화하는 블록도이다.

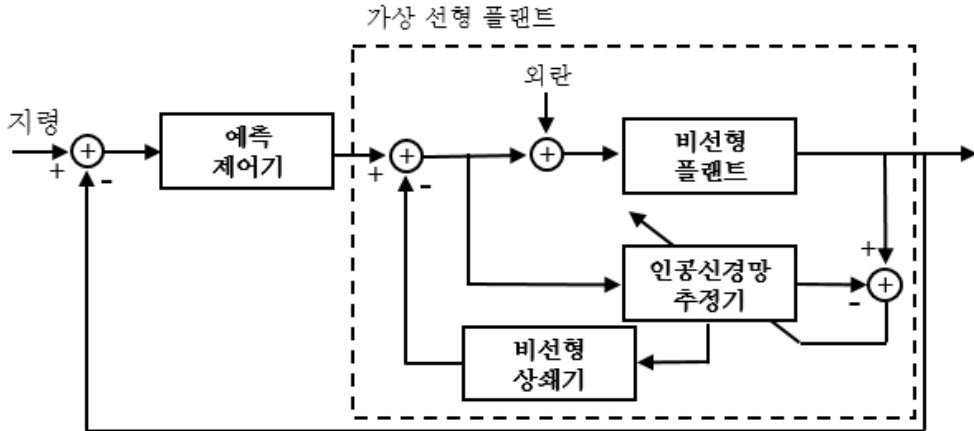


그림 4.1 인공신경망 추정기를 이용한 플랜트의 선형화 블록도 [28]

이 논문의 플랜트 선형화 과정을 SPMSM 비선형 전압 모델의 선형화에 적용할 수 있다. 본 논문에서 다루고자 하는 SPMSM 전압 모델의 비선형성은 인버터의 비선형성과 모델의 제정수를 잘못 알고 있는 것에 기인하기 기인하기 때문에 그림 4.2와 같이 표현할 수 있다.




그림 4.2 비선형성과 왜곡을 포함하여 간략화한 SPMSM 전류제어 블록도

본 논문에서는 [28]에서와 같이 인공신경망을 플랜트 선형화에 이용하지만 인공신경망을 통해서 전체 플랜트를 모의한 후 비선형성을 추출해내는 것이 아니라 그림 4.3과 같이 비선형 플랜트와 선형 모델 사이의 차이를 학습하여 인공신경망이 인버터 비선형성에 의한 전압 왜곡 값을 학습하게 하여 이를 상쇄하고자 한다.

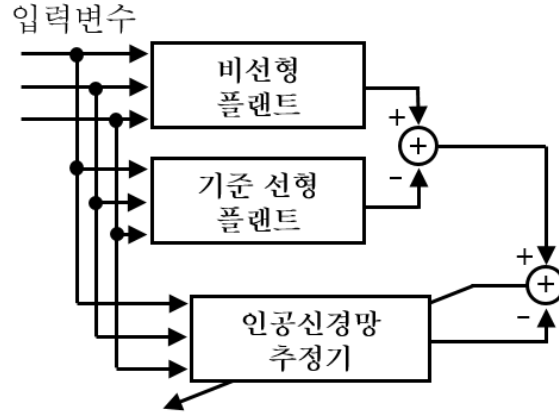


그림 4.3 제안하는 시스템의 인공신경망을 이용한 플랜트 선형화 블록도.

## 4.2 정지 좌표계 인공신경망 인버터 비선형성 추정기

본 논문에서는 정지 좌표계에서 인버터 비선형성이 다른 상의 영향을 받지 않는다는 가정 하에 상 별로 독립적인 신경망을 이용하여 각 상의 비선형성에 의한 전압 왜곡 성분을 전향 보상하는 그림 4.4의 구조로 제어 시스템을 설계하였다.




그림 4.4 정지좌표계에서 인버터 비선형성을 보상하는 인공신경망 추정기를 포함하는 제어 블록도.

### 4.2.1 인공신경망 설계

사용되는 인공신경망은 상 별로 1개씩 총 3개가 사용되지만 스위치 소



자는 대칭이라는 가정하에 같은 변수로 구성된 함수에 입력 변수만 각 상에 해당하는 변수로 할당된다.




그림 4.5 A상 인버터 왜곡 전압 인공신경망 추정기.

인공 신경망 설계에 있어서 중요한 요소는 입·출력 변수 선정이다. 출력 변수는 인공신경망을 비선형성 추정기로 사용하기 때문에 지령 폴 전압과 실제 폴 전압 사이의 차이가 되지만 입력 변수는 해당 오차가 어떤 입력 변수에 대한 함수인지를 고려하여서 선정하여야 한다. 연속 시간 영역의 제어를 하는 경우에 전압 왜곡 값은 상 전류만의 함수이지만 디지털 제어를 하기 때문에 샘플 및 연산 시간을 확보하기 위해서 폴 전압 지령과 실제 인가 폴 전압 사이에는  $1.5T_{\text{samp}}$ 의 지연이 생긴다. 또한 데드존에서 변하는 전류의 평균 값을 계산하기 위해서 추가적인 전류의 예측이 필요하다. 따라서 본 논문에서는 식 (2.1)의 전압 모델을 고려하여 각 상 별 인공신경망의 입력 변수를 식 (4.1)과 같이 선정하였다.

$$\left\{ \begin{array}{l} IN_{a1} = I_a, IN_{a2} = \omega_r \sin(\theta_r + 1.5\omega_r T_{samp}), IN_{a3} = V_{as,ref} \\ IN_{b1} = I_b, IN_{b2} = \omega_r \sin\left(\theta_r + 1.5\omega_r T_{samp} - \frac{2}{3}\pi\right), IN_{b3} = V_{bs,ref} \\ IN_{c1} = I_c, IN_{c2} = \omega_r \sin\left(\theta_r + 1.5\omega_r T_{samp} + \frac{2}{3}\pi\right), IN_{c3} = V_{cs,ref} \end{array} \right\} \quad (4.1)$$

두 번째로 설계할 요소는 활성화 함수의 선정이다. 활성화 함수는 3.1.1 절에서 다룬 바와 같이 해당 은닉 뉴런으로 들어오는 신호를 활성화 또는 비활성화 시켜 시스템을 입력 변수의 상태에 따라서 가변시키는 역할을 한다. ReLU, Tansig, Sigmoid 등 여러 함수들이 있지만 본 연구에서는 오프라인을 통해 Adam 알고리즘을 이용하여 학습된 변수들을 이용하여 온라인 상황의 시작 변수로 삼기 때문에 오프라인에서의 신경망과 온라인에서의 신경망이 동일해야 한다. 하지만 DSP에서 구동되는 시스템은 샘플링 주기의 제약에 의해 초월함수를 근사해야 하기 때문에 Tansig나 Sigmoid등 초월 함수 기반의 활성화 함수를 이용할 경우 오프라인에서 학습이 완료된 신경망임에도 불구하고 온라인 상황에서 큰 오차를 발생시킨다. 따라서 초월 함수를 이용하지 않고 활성화, 비활성화 여부만 판별하는 ReLU를 활성화 함수로 선정하여 오프라인 학습의 효과를 극대화시켰다.

세 번째로 설계할 요소는 은닉 뉴런의 배치를 통한 인공신경망 내부 구조 설계이다. 은닉뉴런은 은닉 층의 개수와 각 층 내의 은닉 뉴런의 개수에 대한 자유도를 지닌다. ReLU의 경우 은닉 뉴런의 개수에 따라서 가변 시스템의 조합의 종류가 결정된다. 하지만 같은 은닉 뉴런의 개수 내에서 은닉 층이 늘어날수록 연산량이 많아지기 때문에 활성화 함수 ReLU만 쓰는 경우에는 은닉 층을 1개만 가져가는 것이 가장 효율적이다. 은닉 층 1개 내에서 은닉 뉴런의 수는 뉴런의 수를 변화시켜가며 MATLAB 내부 함수 Adam을 이용하여 오프라인 학습을 진행한 결과를

통해 결정하였다. 그림 4.6은 입력 데이터에 대하여 추출된 상 전압 오차 데이터와 학습이 완료된 인공 신경망을 통한 데이터 사이의 평균 제곱 오차를 은닉 뉴런의 수에 따라서 나타낸 그래프이다. 은닉 뉴런의 개수가 2개에서 3개로 변할 때 성능이 급격하게 향상되며 그 이후로는 연산량 증가에 비하여 큰 성능 증가가 나타나지 않는다. 본 연구에서는 온라인 학습 시 추가로 고려될 비 선형성에 대처하기 위하여 포화 은닉뉴런 개수인 3개에서 2개를 더해 총 5개의 은닉 뉴런을 이용하였다.




그림 4.6 상전압 오차 데이터에 대하여 은닉 뉴런 수에 따른 성능 비교 그래프.

#### 4.2.2 인공신경망 학습

본 논문에서는 실시간으로 변수들을 업데이트하면서 보상하는 온라인 보상 기법이 아니라 사전의 학습을 통하여 정해진 변수들을 이용한 오프라인 보상 기법을 이용했음에도 불구하고 학습 기법은 오프라인 학습과 온라인 학습을 단계별로 모두 사용하였다. 오프라인 학습이 필요한 이유는 첫째로 오프라인 학습을 거치지 않고 온라인 학습을 할 경우 인공신경망의 초기 변수들이 임의의 값으로 설정되어 시스템이 발산할 수 있기

때문이며 둘째는 온라인 학습은 DSP에 구현해야 하며 샘플링 시간 이내에 모든 상의 연산과 학습을 끝내야 한다는 시간적인 제약이 있기 때문에 adaptive learning rate나 관성을 고려한 알고리즘을 적용할 수 없어 지역 최소 손실 점으로 변수가 수렴할 수 있는 단점이 있기 때문이다. 온라인 학습이 필요한 이유는 실시간으로 변화하는 온도와 같은 입력 변수에 고려되지 않은 변수의 변동이나 실제 적용되는 시스템에서 전류센서의 오차, 스위치 소자 별 비 대칭성 등에 대응하기 위해서 필요하다. 본 연구에서는 온라인 학습을 2.4.2절에서 언급한 방식과 같이 보상과 함께 하고 있는 것이 아니라 운전조건이나 플랜트가 변화하였을 경우에만 실시하여 미세 변수를 보정하는 용도로 사용하였다.

오프라인 학습은 3.2.2절에서 다룬 바와 같이 데이터 추출단계와 데이터 학습단계로 나누어 진행하였다. 데이터 추출은 그림 4.7의 블록도를 통해서 입력변수로 선정한 세가지 상태변수에 따른 실제 상 전압과 선형 모델을 통해 추정한 상 전압의 차이인 상 전압 오차를 추출하였다. 사용된 기준 선형 모델은 식 (4.2)의 모델을 사용하였다.

$$\tilde{V}_{abcs} = \tilde{R}_s I_{abcs} + \tilde{L}_s \frac{dI_{abcs}}{dt} + \tilde{E} \quad (4.2)$$

실제 상 전압의 경우에는 회로를 변형하지 않고서 직접 측정하는 것이 불가능하기 때문에 PI제어기 출력 값을 사용하였다.

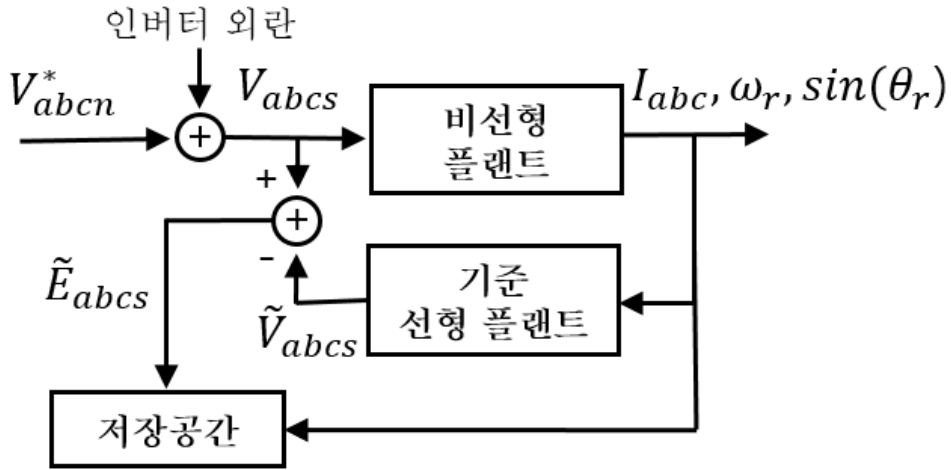




그림 4.7 오프라인 학습 데이터 추출 블록도.


데이터를 추출하는 환경은 부하 전동기와 대상 전동기의 축을 결합된 부하전동기로 속도 제어를 하면서 대상 전동기에서 동기 좌표계 d축 전류 제어를 하며 데이터를 추출하였다. 데이터를 추출하는 속도 영역은  $\pm 0.04\text{p.u.}$ ,  $\pm 0.4\text{p.u.}$ ,  $\pm 0.8\text{p.u.}$  여섯 가지 속도 영역에서 추출한 데이터를 상용하였고 전류 범위는 저 전류 구간의 캐패시터에 의한 비선형성을 추출하기 위한  $0.01\text{p.u.}$  (전동기 정격  $0.1\text{p.u.}$ )와 고정자 전체 운전 영역의 데이터를 추출하기 위한  $0.08\text{p.u.}$ 를 사용하였다. 마찰에 의하여 속도에 따라서 부하가 달라지기 때문에 속도를 음과 양으로 가변하는 것을 통해 다양한 Motoring/Generating 모드 모두 학습 범위에 포함을 시켰다. 오프라인 학습에 이용된 전체 데이터 셋은 그림 4.8와 같다.



(가)



(나)



(다)



(라)

그림 4.8 오프라인 학습 데이터 추출을 위한 운전 조건.

(가) 전류 운전 조건 변화 파형, (나) 속도 운전 조건 변화 파형,  
(다) 회전자 각도 데이터 파형, (라) 상 전압 오차 파형.

오프라인 학습의 성능 척도는 전체 데이터 셋에 대해서 전압 오차와  
인공신경망의 출력의 차이의 평균제곱오차(MSE)이다. 성능 척도가 가장  
작은 것을 목표로 하며 사건에 저장한 그림 4.8의 데이터 셋을 이용하  
여 Adaptive learning rate와 Momentum 개념을 모두 적용한 Adam 알고리  
즘을 적용하였다. 오프라인 학습의 블록도는 그림 4.9와 같다.

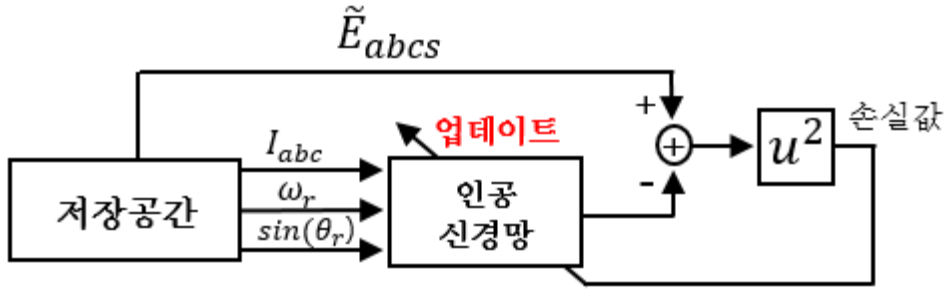


그림 4.9 오프라인 학습 구조 블록도.

총 학습은 5713번을 진행하였고 그림 4.10(가)는 학습이 완료된 후 원 파형과 인공신경망의 출력을 비교한 그래프이다. (나)는 초반 500번 학습에 대해서 학습이 진행됨에 따라서 손실 값의 합이 줄어드는 과정을 나타낸 그래프이다. 오프라인 학습의 결과 변수는 부록 A.2에 첨부되어 있다.

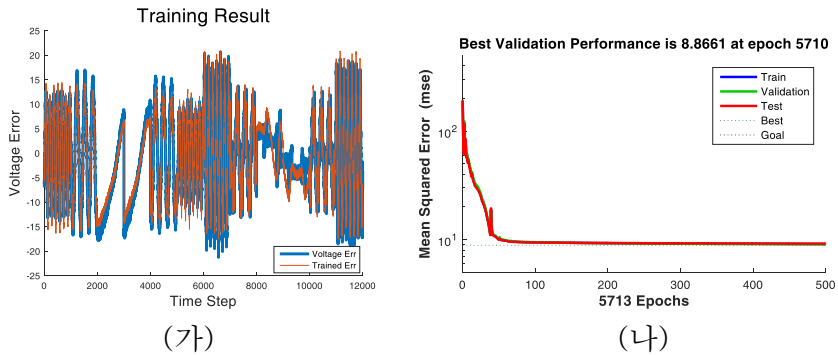


그림 4.10 오프라인 학습 결과 파형.

다음 단계는 온라인 학습이다. 온라인 학습에서의 인공신경망의 초기 변수 값은 오프라인 학습을 통해서 선정된 값을 사용하였으며 학습 구조는 그림 4.11와 같다. 성능 척도는 오프라인 학습 시 사용하였던 전압 오차 외에도 상 전류 THD 성능 향상을 위해서 전류 오차를 함께 반영하여 식 (4.3)과 같이 선정하였다.  $a_0, a_1$ 은 정규화하기 위한 상수로서 각

항의 정격 값의 역수를 사용하였다.

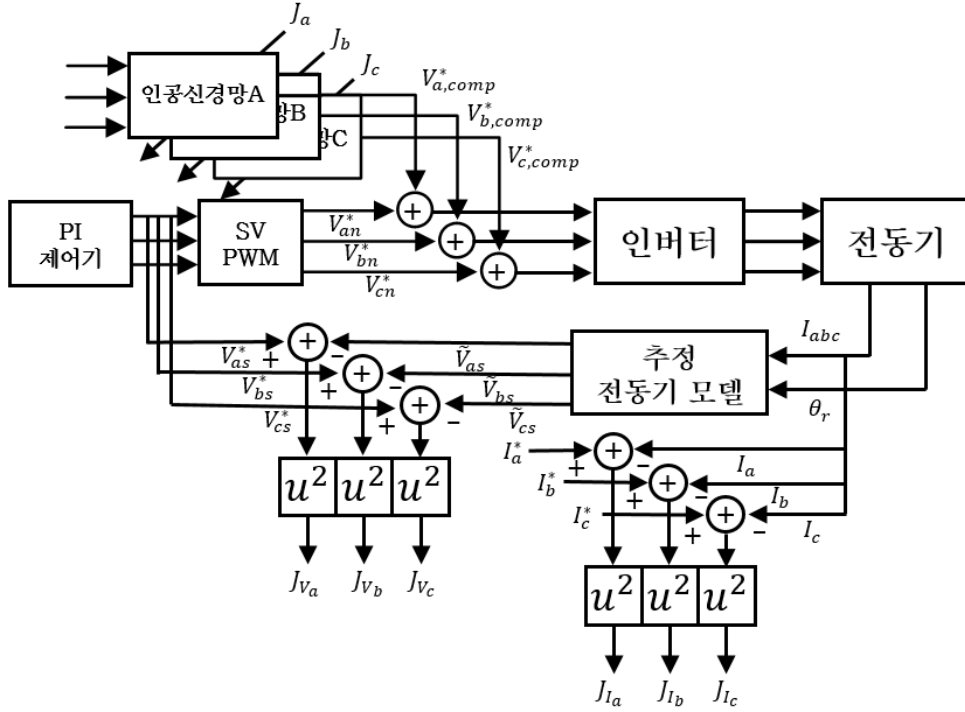


그림 4.11 온라인 학습 구조 블록도.

$$\begin{aligned}
 J_a &= a_0(V_{as}^* - \tilde{V}_{as})^2 + a_1(I_a^* - \tilde{I}_a)^2 \\
 J_b &= a_0(V_{bs}^* - \tilde{V}_{bs})^2 + a_1(I_b^* - \tilde{I}_b)^2 \\
 J_c &= a_0(V_{cs}^* - \tilde{V}_{cs})^2 + a_1(I_c^* - \tilde{I}_c)^2
 \end{aligned} \tag{4.3}$$

각 상 정보를 통해서 생성된 손실 값은 다음 time step에서 사용될 각 인공신경망의 변수를 업데이트하는데 쓰인다



## 제 5 장 실험 결과

본 장에서 제 4 장에서 언급한 제안하는 딥 러닝을 이용한 인버터 비선형성 보상 방법을 기존 방법과의 비교를 통하여 성능을 검토한다. 5.1절에서는 보상 알고리즘이 적용될 실험 세트의 구성에 대해서 설명하고 5.2절에서는 정상상태(동기 좌표계 전류 크기, 부하각, 전류제어기 대역폭)와 과도상태의 다양한 실험 조건에서 보상 성능을 검증한다. 성능의 지표는 1) 기준 모델의 전압과 상 전압 지령과의 오차, 2) 동기 좌표계 d축 전류 지령과 d축 전류 사이의 오차, 3) q축 전류 지령과 q축 전류 사이의 오차 세 가지의 RMS 값과 Peak to Peak값을 비교하였다.

### 5.1 실험 세트 구성

본 실험의 실험 장치는 알고리즘이 적용될 대상 전동기와 대상 전동기의 다양한 조건을 모의하기 위한 부하전동기의 축을 연결하여 각을 공유하는 형태로 구성하였다. 전체 시스템은 그림 5.1과 같이 전동기와 전동기 구동회로의 쌍으로 이루어져 있다. 대상 전동기와 부하 전동기는 LS 메카피온 사의 APM-SC10ADK 모델(1kW)로 동일한 표면 부착형 동기 전동기(Surface Permanent Magnetic Synchronous Machine, SPMSM)가 적용되었으며 전동기의 제정수 및 정격 조건은 표 A.1에 기술되어있다. 전동기 구동 회로는 3상 IGBT 모듈 인버터(Mitsubishi Electric 사의 PS21A79 50A 정격)를 사용하였으며 대상전동기와 부하전동기는 동일한 구동 회로를 통해서 구동하였다. 직류단 전원은 220V AC 계통 전원을 정류한 전압(310V)을 사용하였으며 대상 전동기 직류단 전압 캐패시터와 부하 전동기 직류단 전압 캐패시터는 서로 병렬로 연결되어 전압을 공유하고 있다.

제어 알고리즘이 탑재된 DSP는 TI사의 TMS320C28346이 사용되었으며 대상전동기의 DSP에 보상 알고리즘을 포함한 전류 제어 알고리즘이 탑재되었으며 부하전동기에 속도제어, 전류제어 알고리즘이 탑재되었다.




그림 5.1 부하전동기와 대상 전동기 M-G세트와 구동회로.

## 5.2 보상 성능 검증

보상 알고리즘의 목적은 비선형성의 상쇄이기 때문에 플랜트의 선형화가 목표이다. 플랜트의 선형화된 모델은 학습 시 이용한 선형화 모델인 식 (5.1)을 사용하였기 때문에 실제 상 전압의 식 (5.1)을 통해서 계산

된 상 전압과의 오차와 오차에 의해서 발생하는 전류 왜곡을 성능 척도로 삼는다.

$$\tilde{V}_{abcs} = \tilde{R}_s I_{abcs} + \tilde{L}_s \frac{dI_{abcs}}{dt} + \tilde{E} \quad (5.1)$$

보상 전압은 그림 5.2와 같은 구조로 폴 전압 지령을 수정하는 형태로 사용되며 기본 PI제어기, 사다리꼴 보상, 아크 탄젠트 보상 총 세가지 알고리즘을 제안하는 알고리즘과 비교하였다.




그림 5.2 성능비교를 위한 보상 알고리즘이 포함된 제어 블록도.

운전 조건은 전압 왜곡이 두드러지는 저속(0.2p.u.) 저 전류(0.01p.u) 조건 하에서 비교하였고 부하각과 전류제어기 대역폭을 변화시키며 학습시키지 않은 조건에 대해서 보상 성능을 확인함을 통해 학습의 일반화를 검증하였다.

### 5.2.1 정상 상태 보상 성능 확인

운전조건을 변화시키기 이전에 오프라인 학습에 사용된 운전 조건 중 하나인 식 (5.2)의 운전조건에서의 제안하는 알고리즘의 플랜트 선형화 성능을 다른 오프라인 기반 보상 기법인 사다리꼴, 아크탄젠트 기반의 보상 방법과 전류 THD를 통해서 비교하였다.

$$\omega_{r/min} = -500 \text{r/min}, I_{dsr}^* = 1 \text{A}, I_{qsr}^* = 0 \text{A} \quad (5.2)$$

그림 5.4는 각각의 보상 방법에 대한 실험 결과 파형이며 그림 5.3은 각 보상방법 별 전류 파형에 대한 THD 분석 결과이다. 인공신경망을 사용한 경우 추정 상 전압과 상 전압 지령이 가장 유사하며 THD값이 가장 낮게 나와 상 전류가 가장 사인 함수에 가까운 것을 확인할 수 있다.







그림 5.3 보상 방법에 따른 THD 비교 그래프.




(가) 비 보상



(나) 사다리꼴 보상



(다) 아크탄젠트 보상



(라) 딥러닝 보상

그림 5.4 보상방법별 모델 상 전압, 상 전류 비교 실험파형.

첫 번째 성능을 확인할 조건은 동기 좌표계  $q$ 축 전류 크기에 따른 보상 성능이다. 표면 부착형 동기전동기의 경우  $q$ 축 전류는 토크와 비례하는 성분이기 때문에  $q$ 축 전류 성능은 토크 제어 성능과 밀접한 관련이 있다. 동기 좌표계에서는 변하지 않는 고정된 상수 지령이지만 정지 좌표계에서는 AC 형태로 인가되기 때문에 본 실험은 해당 영역에서 변화하는 외란 값을 보상하는 성능을 확인할 수 있는 실험이다. 총 세가지 전류  $2A(0.04p.u)$ ,  $1A(0.02p.u)$ ,  $0.5A(0.01p.u)$  전류에 대해서 실험을 진행하였다. 동기 좌표계 지령을 특정값으로 지정하였을 때 확인할 수 있는 보상 영역은 절대값이 해당 지령 값보다 작은 전류에 대하여 모두 해당된다. 그림 5.5는 각 실험 조건이 전압 왜곡 양에서 어떤 위치에 해당하는지를 나타낸 그래프이다.




그림 5.5 전류에 따른 전압 왜곡 양 피팅 그래프.

첫 번째 비교 실험은  $q$ 축 동기 좌표계 지령  $2A(0.04p.u)$ 에서 진행된 실험이다.  $2A$ 보다 큰 전류에 대해서는 데드존에서 다이오드를 막는 역전압 캐패시터의 전하가 순식간에 빠져나가 보상해야 하는 값이 변하지 않는 상수 값이기 때문에 PI제어기가 보상을 할 수 있다. 따라서 실험에서 사용된 영역 중 가장 넓은 영역을  $2A(0.04 p.u)$ 로 선정하여 이보다 큰 영역을 대표하는 경우로 삼았다. 보상을 하지 않은 경우 2.3.2절에서 언급한 바와 같이 6고조파 리플이 발생한다. 이에 비하여 사다리꼴, 아크탄젠트, 딥 러닝 보상방식은 6고조파 리플을 억제함을 확인할 수 있다. 이에 따라서 스위치 기생 캐패시터 모델을 고려한 보상 방법인 사다리꼴과 아크탄젠트 보상 방안이 적절히 세팅 되었음을 확인할 수 있다.

하지만 이와 같이 피팅된 보상 값을 이용하여 더 작은 동기 좌표계 전류( $1A, 0.5A$ )를 제어하고자 할 때 문제가 발생하는 것을 그림 5.11를 통해서 확인할 수 있다. 더 작은 동기 좌표계 전류의 의미는 상 전류를 영 전류 근처에서만 변화하게 만들어 해당 보상 기법이 영 전류 근처에서도 정상적으로 동작하는지 확인하기 위함이다. 이 경우에 전류 크기가 점점 작아질수록 사다리꼴 보상 기법과 아크탄젠트 보상 기법의 리플이 발생하고 그림 5.11에서는 보상을 하지 않은 경우보다도 더 큰 리플을 발생시키게 된다. 이에 반해 제안하는 딥러닝 보상 기법은  $1A(0.01p.u)$ 에서도 같은 수준으로 제어하고 있음을 확인할 수 있다.







그림 5.6 q축 2A(0.04p.u) 제어 실험 시 확인되는 보상 영역.




(가) 비 보상



(나) 사다리꼴 보상



(다) 아크 탄젠트 보상



(라) 딤러닝 보상

그림 5.7 2A(0.04p.u)에서 각 보상방법에 따른 전류 파형.






그림 5.8 q축 1A(0.02p.u) 제어 실험 시 확인되는 보상 영역.







그림 5.9 1A(0.04p.u)에서 각 보상방법에 따른 전류 파형.




그림 5.10 q축 0.5A(0.01p.u) 제어 실험 시 확인되는 보상 영역.




그림 5.11 0.5A(0.01p.u)에서 각 보상방법에 따른 전류 파형.

두 번째 성능을 확인할 조건은 **부하 각에 따른 실험 결과**이다. 앞선 실험 결과에서 살펴봤듯이 데드 타임에 의한 전압왜곡을 보상하기 위해서는 전류의 예측이 필요하다. 하지만 전류의 예측을 하기 위해서는 해당 부하 전류 조건에서 역기전력 정보가 필요하다. 따라서 보상 값을 결정하는 함수는 단순히 전류의 함수가 아닌 역기전력의 함수로 설정이 되어야 한다. 역기전력을 잘 반영하여 보상하였는지에 관한 실험 결과는 동기 좌표계 전류 지령을 다르게 주어 부하 각을 변동시켜가며 각 상 전류 상태에서 발생하는 각 상의 역기전력을 다르게 만들어냄으로써 확인할 수 있다. 본 실험에서는 그림 5.12와 같이 360도의 부하 각을 총 45도씩 8개로 쪼개어 실험을 진행하였다. 실험 조건은 예측 전류를 반영하지 않아 생기는 왜곡이 발생하기 이전인  $I_{mag}^* = 1A(0.02p.u)$ ,  $\omega_{rm} = 500rpm$ 로 진행하였다.




그림 5.12 정상상태 부하각에 따른 전류제어 성능 위한 영역 구분.  
본 실험의 결과는 그림 5.13~그림 5.18을 통해서 확인할 수 있는데

모든 부하조건에서 비교하고자 하는 보상 기법에 비하여 rms 오차가 줄어들은 것을 확인할 수 있다.




그림 5.13 상전압 오차 RMS 결과 그래프.




그림 5.14 상전압 오차 Peak to Peak 결과 그래프.




그림 5.15 D축 전류 오차 RMS 결과 그래프.




그림 5.16 D축 전류 오차 Peak to Peak 결과 그래프.




그림 5.17 Q축 전류 오차 RMS 결과 그래프.






그림 5.18 Q축 전류 오차 Peak to Peak 결과 그래프

세 번째 확인할 정상상태 실험조건은 동기 좌표계 제어기 대역폭에 따른 보상 성능 결과이다. 대역폭이 유사한 제어기가 같은 변수를 제어하고 있는 경우에 간섭이 일어나서 공진을 일으키듯이 전류를 기반으로 하는 전압 전향 보상 알고리즘은 전류 제어기와 같이 사용될 경우 간섭을 일으켜 제어에 방해할 수 있다. 따라서 전류 제어기 대역폭에 따라서 보상 알고리즘이 제어에 끼치는 영향을 보는 것은 중요하다.

성능 척도는 부하 각에 따른 성능 비교 실험과 동일하게 전압 오차, d축 전류 오차, q축 전류 오차 세 가지 요소에 대해서 RMS 값과 Peak to Peak값에 대해서 비교하였다. 이 경우 대역폭이 낮은 상황 속에서 인공 신경망 제어기가 기존 보상방법에 비하여 상 전압 오차에서 안 좋은 성능을 보여준다. 이는 전류 제어기 대역폭이 높은 상황 속에서는 PI제어기 출력이 실제 상 전압을 대표할 수 있어 기준 모델과 현재 얼마나 어긋나 있는지를 확인하여 적절한 손실 값을 삼을 수 있지만 대역폭이 낮은 상황 속에서는 PI제어기 출력이 느리게 동작하여 실제 상 전압 대비 시 지연을 지니게 되어 선형 모델을 피팅하기에 적절한 지표가 아니기 때문이다. 이 경우에는 전류 오차를 통해서 보상 성능을 확인할 수 있는데 D축, Q축 모든 경우에서 비교하고자 하는 오프라인 기반 보상 방법에 비해 RMS 오차가 작은 것을 확인할 수 있다.




) 상 전압 오차 RMS,




(나) 상 전압 오차 Peak to Peak.

그림 5.19 전류제어기 대역폭 별 각 보상 알고리즘의 상 전압 오차 비교 그래프







(가) D축 전류 오차 RMS,



(나) D축 전류 오차 Peak to Peak.

그림 5.20 전류제어기 대역폭 별 각 보상 알고리즘의 동기 좌표계 d축 전류 오차 비교 그래프



(나) Q축 전류 오차 Peak to Peak.

그림 5.21 전류제어기 대역폭 별 각 보상 알고리즘의 동기 좌표계 Q축 전류 오차 비교 그래프.

### 5.2.2 과도 상태 보상 성능 확인

본 절에서 확인할 성능은 과도상태에서의 보상 성능이다. PI제어기를 통하여 과도상태를 제어하는 시스템에서 전압 지령은 현재 동기 좌표계 전류 오차 및 누적된 오차에 의해서 생성된다. 하지만 실시간으로 변하는 전압 외란이 형성될 경우 PI제어기는 외란에 의한 오차까지 추가적으로 보상해야 하기 때문에 수렴성능에 제한이 생길 수 있다. 본 절에서는 과도상태 반응성을 살펴보기 위하여 그림 5.22와 같이 전체 전기각을 세 구간으로 나누었다. 이는 데드타임이 발생하는 A,B,C세 상이 대칭이기 때문에 그 중 한 영역만 살펴보기 위함이며 한 영역 내에서는 4가지 운전점을 나누어  $45^\circ, 15^\circ, -15^\circ, -45^\circ$  각 운전점에서 반응성을 확인하는 실험을 진행하였다. 실험 결과는 그림 5.24~그림 5.30과 같다.




그림 5.22 과도상태 보상실험을 위한 전기각 영역 구분.

다른 보상방안에서는 각도에 따라서 지령값에 도달하는 시간이 달라지는 반면 제안하는 딥러닝 보상방안은 동일하게 도달하는 것을 확인할수 있다.




그림 5.23 45도 전기각 위치




그림 5.24 45도 전기각 위치에서의 과도상태 보상 실험.







그림 5.25 15도 전기각 위치




(가) 보상 없음



(나) 사다리꼴 보상



(다) 아크 탄젠트 보상



(라) 딥러닝 보상

그림 5.26 15도 전기각 위치에서의 과도상태 보상 실험.






그림 5.27 -15도 전기각 위치




(가) 보상 없음



(나) 사다리꼴 보상



(다) 아크 탄젠트 보상



(라) 딥리닝 보상

그림 5.28 -15도 전기각 위치에서의 과도상태 보상 실험.






그림 5.29 -45도 전기각 위치



(가) 보상 없음

(나) 사다리꼴 보상




(다) 아크 탄젠트 보상

(라) 딥리닝 보상


그림 5.30 -45도 전기각 위치에서의 과도상태 보상 실험.

두 번째 과도상태 보상 실험은 보상 방안에 따라 한계 전류제어 대역폭을 확인하는 실험이다. 전류제어 대역폭의 한계는 리플의 크기에 따라서 결정되기 때문에 높은 제어기 대역폭에서 낮은 리플을 발생시키는 것은 중요하다. 그림 5.31은 20kHz 샘플링 조건하에 전류제어기 대역폭 3kHz에서의 실험결과이다. 파형을 통해 살펴보면 제안하는 보상방안은 3kHz에서 구동이 가능하지만 다른 보상방안은 전류파형의 왜곡이 심하여 3kHz에서 구동하지 못하는 것을 확인할 수 있다.



(가) 보상 없음

(나) 사다리꼴 보상



(다) 아크 탄젠트 보상

(라) 딥러닝 보상

그림 5.31 3kHz 전류제어기 대역폭에서의 과도상태 보상 실험.



## 제 6 장 결론 및 향후 연구

본 연구는 인버터 비 선형성에 의해서 생기는 전압 왜곡을 보상하는 기존 방법에서 고려하지 못한 비선형적으로 증가하는 전류를 예측하기 위해서 딥러닝을 적용하였다.

3상 AC전동기를 구동하기 위해서 널리 쓰이고 있는 2레벨 전압형 인버터의 경우 윗 상과 아랫 상을 상보적으로 동작시키며 폴 전압을 전동기에 인가하는 방식으로 전력을 공급한다. 하지만 전압형 인버터의 특성상 단락 사고에 취약하며 이를 방지하기 위해서 각 상의 스위치 조합이 변화하는 사이에 어느 스위치도 켜져 있지 않은 데드존이 형성되어야 한다. 하지만 이 데드존 때문에 Duty가 달라지게 되어 폴 전압이 왜곡되게 되는데 왜곡 되는 전압을 정확하게 알아야 해당 Duty 왜곡을 상쇄하는 수정된 전압 지령을 낼 수 있기에 이에 대한 분석이 많이 행해져 왔고 보상 성능을 통하여 보여져 왔다. 기존 연구에서는 보상 전압을 전류가 흐르는 소자에 따라 전류의 방향에 따라서 부호를 결정하였고 스위치에 병렬로 연결된 기생 캐패시터에 의해서 전류 크기에 대한 함수로 값을 결정하였다. 하지만 이 전류는 데드존에서의 전류인데 이를 직접 측정하는 것은 기존의 PWM시스템에서 어렵기 때문에 샘플링 시점에서 이를 예측하거나 온라인으로 해당 값을 알아내는 연구가 행해져 왔다. 하지만 예측하는 방식은 선형 시스템을 이용했다는 한계를 지니고 있으며 온라인으로 알아내는 연구는 정상상태에서만 적용 가능하다는 한계를 지니고 있다.

본 논문에서는 이를 해결하기 위해 비선형 시스템을 모의할 수 있는 인공신경망을 이용하여 샘플링 시점으로부터 비선형적으로 증가하는 전류와 전류에 따른 비선형적인 전압 보상 값의 함수가 결합된 함수를 모

의하는 방법을 제안하였다. 인공신경망은 비선형적인 특성을 모의가 가능하다는 장점 덕분에 다양한 비선형성이 존재하는 어플리케이션에 많이 사용되었다. 하지만 통상적인 인공신경망 연구에서는 학습 도중 시스템이 발산할 수 있다는 문제점과 국소 최소점에 머무를 수 있다는 단점에 의해 제어 시스템에 적용하기 위한 방법이 필요하다. 본 논문에서는 학습의 단계를 오프라인과 온라인으로 나누는 방식을 제안하였다. 오프라인 학습을 통해서 한 스텝 학습 시간에 영향 받지 않는 전역 최소값을 찾는 알고리즘을 적용하였고 온라인 학습을 통해 세부 구동 상황에 따라 변하는 값에 대해 국소 최소점을 찾는 알고리즘을 이용하여 이를 최적화하였다. 온라인 학습을 하는 경우에 입력 변수로 선정되지 않은 변수의 변동을 변수가 대응해야 할 경우 변수 변동이 커져 시스템이 불안정해질 수 있는 문제점을 막기 위해서 입력 변수에 플랜트의 전압 왜곡 예측값과 관련된 입력인 상전류, 상 전압 지령, 역기전력으로 전압 보상 값에 영향을 주는 변수들로 삼았다. 제안된 알고리즘을 통해 저 전류(0.01p.u.) 영역에서 성공적으로 인버터 비선형성을 보상하였고 동기 좌표계 전류 크기, 부하 각, 전류 제어기 대역폭의 변화에 따른 정상상태 운전과 저 전류 스텝 입력 실험을 통한 과도상태 운전을 기존 정상상태 테이블을 피팅하는 방법들과 비교하여 성능을 검증하였다.

본 연구의 향후 연구는 다음과 같다.

- 1) 본 연구는 활성화 함수를 통하여 가변하는 인공신경망 시스템을 이용하여 비선형성을 상쇄하였다. 하지만 가변하는 시스템의 특성상 기존의 선형 시스템을 대상으로 하는 안정도 분석 기법이 성립하지 않는다. 따라서 소신호 분석 방법을 통해 가변하는 시점에서의 안정도는 판별하지 못하더라도 변화된 매 시스템 내에서 안정성을 판별하는 기법을 이용하여 최소한의 안정도 판별이 요구된다.

2) 본 연구에서 학습을 하기 위한 성능 척도는 매 샘플링 시점에서의 상 전압 오차와 상 전류 오차를 이용하였다. 하지만 본 논문의 대상 범위인  $0.01\text{p.u}$  보다 작은 전류 특히 영 전류 제어를 하는 상황 속에서 전류 센서 노이즈에 의한 신호 왜곡이 학습에 반영되기 때문에 주어진 입력 변수의 상태가 같다고 하더라도 다른 전압 오차를 만들어 내기 때문에 이를 적절히 분류해내지 못한다면 외란의 모델을 왜곡할 수 있다. 오프라인으로 학습을 진행하기 때문에 학습을 위하여 추출된 신호에 대하여 전 처리를 할 시간이 충분히 주어지므로 화이트 노이즈를 억제하는 여러 신호처리 알고리즘을 적용할 경우 좀 더 낮은 전류 범위까지 적용 가능하도록 알고리즘을 발전시킬 수 있다.

## 참고 문헌

- [1] K. Hyun-Soo, M. Hyung-Tae, and Y. Myung-Joong, "On-line dead-time compensation method using disturbance observer," *IEEE Transactions on Power Electronics*, vol. 18, no. 6, pp. 1336–1345, 2003.
- [2] N. Urasaki, T. Senjyu, T. Funabashi, and H. Sekine, "Adaptive dead-time compensation strategy taking parasitic capacitance effects into account," in *2005 IEEE International Conference on Industrial Technology*, 2005, pp. 1109–1114.
- [3] N. Urasaki, T. Senjyu, K. Uezato, and T. Funabashi, "Adaptive Dead-Time Compensation Strategy for Permanent Magnet Synchronous Motor Drive," *IEEE Transactions on Energy Conversion*, vol. 22, no. 2, pp. 271–280, 2007.
- [4] S. Ahmed, Z. Shen, P. Mattavelli, D. Boroyevich, and K. J. Karimi, "Small-Signal Model of Voltage Source Inverter (VSI) and Voltage Source Converter (VSC) Considering the DeadTime Effect and Space Vector Modulation Types," *IEEE Transactions on Power Electronics*, vol. 32, no. 6, pp. 4145–4156, 2017.
- [5] L. Ben-Brahim, A. Gastli, and K. Ghazi, "Implementation of iterative learning control based deadtime compensation for PWM inverters," in *2015 17th European Conference on Power Electronics and Applications (EPE'15 ECCE-Europe)*, 2015, pp. 1–8.
- [6] A. Guha and G. Narayanan, "Small-Signal Stability Analysis of an Open-Loop Induction Motor Drive Including the Effect of Inverter Deadtime," *IEEE Transactions on Industry Applications*, vol. 52, no. 1, pp. 242–253, 2016.
- [7] Z. Hengbing, Q. M. J. Wu, and A. Kawamura, "An accurate approach of nonlinearity compensation for VSI inverter output voltage," *IEEE Transactions on Power Electronics*, vol. 19, no. 4, pp. 1029–1035, 2004.
- [8] S. Y. Kim and S. Y. Park, "Compensation of Dead-Time Effects Based on Adaptive Harmonic Filtering in the Vector-Controlled AC Motor Drives," *IEEE Transactions on Industrial Electronics*, vol. 54, no. 3, pp. 1768–1777, 2007.
- [9] D. M. Park and K. H. Kim, "Parameter-Independent Online Compensation Scheme for Dead Time and Inverter Nonlinearity in IPMSM Drive Through Waveform Analysis," *IEEE Transactions on Industrial Electronics*, vol. 61, no. 2, pp. 701–707, 2014.
- [10] T. Qiu, X. Wen, and F. Zhao, "Adaptive-Linear-Neuron-Based Dead-Time Effects Compensation Scheme for PMSM Drives," *IEEE Transactions on Power Electronics*, vol. 31, no. 3, pp. 2530–2538, 2016.

- [11] F. Blaabjerg, J. K. Pedersen, and P. Thøgersen, "Improved modulation techniques for PWM-VSI drives," *IEEE Transactions on Industrial Electronics*, vol. 44, no. 1, pp. 87–95, 1997.
- [12] C. Jong-Woo and S. Seung-Ki, "A new compensation strategy reducing voltage/current distortion in PWM VSI systems operating with low output voltages," *IEEE Transactions on Industry Applications*, vol. 31, no. 5, pp. 1001–1008, 1995.
- [13] R. J. Kerkman, D. Leggate, D. W. Schlegel, and C. Winterhalter, "Effects of parasitics on the control of voltage source inverters," *IEEE Transactions on Power Electronics*, vol. 18, no. 1, pp. 140–150, 2003.
- [14] Y. Murai, A. Riyanto, H. Nakamura, and K. Matsui, "PWM strategy for high frequency carrier inverters eliminating current clamps during switching dead-time," in *Conference Record of the 1992 IEEE Industry Applications Society Annual Meeting*, 1992, pp. 317–322 vol.1.
- [15] Y. Park and S. K. Sul, "Implementation Schemes to Compensate for Inverter Nonlinearity Based on Trapezoidal Voltage," *IEEE Transactions on Industry Applications*, vol. 50, no. 2, pp. 1066–1073, 2014.
- [16] R. B. Sepe and J. H. Lang, "Inverter nonlinearities and discrete-time vector current control," *IEEE Transactions on Industry Applications*, vol. 30, no. 1, pp. 62–70, 1994.
- [17] N. Urasaki, T. Senjyu, T. Kinjo, T. Funabashi, and H. Sekine, "Dead-time compensation strategy for permanent magnet synchronous motor drive taking zero-current clamp and parasitic capacitance effects into account," *IEE Proceedings – Electric Power Applications*, vol. 152, no. 4, pp. 845–853, 2005.
- [18] Y. Wang, F. Gao, and F. J. Doyle, "Survey on iterative learning control, repetitive control, and run-to-run control," *Journal of Process Control*, vol. 19, no. 10, pp. 1589–1600, 2009/12/01/ 2009.
- [19] L. M. Gong and Z. Q. Zhu, "Modeling and compensation of inverter nonlinearity effects in carrier signal injection-based sensorless control methods from positive sequence carrier current distortion," in *2010 IEEE Energy Conversion Congress and Exposition*, 2010, pp. 3434–3441.
- [20] J.-I. H. Hyung-Min Ryu, Seung-Ki Sul, Kozo Ide, Yoichi Yamamoto, Eiji and Watanabe, "Compensation of Voltage Distortion in PWM-VSI by Prediction of Stator Currents at Switching Point," *Conf. Rec. of IEEJ, Annual Meeting*, vol. 3, pp. 87–90, April 1999.
- [21] S. Ahmed *et al.*, "Small-signal model of a voltage source inverter (VSI) considering the dead-time effect and space vector modulation types," in *2011 Twenty-Sixth Annual IEEE Applied Power Electronics Conference and Exposition (APEC)*, 2011, pp. 685–690.
- [22] J.-I. H. Hyung-Min Ryu, Seung-Ki Sul, Kozo Ide, Yoichi Yamamoto, Eiji and Watanabe, "Compensation of Voltage Distortion in PWM-VSI

- by Prediction of Stator Currents at Switching Point," *Conf. Rec. of IEEJ, Annual Meeting*, vol. vol.3, pp. 87–90, 1999.
- [23] B. K. Bose, "Neural Network Applications in Power Electronics and Motor Drives—An Introduction and Perspective," *IEEE Transactions on Industrial Electronics*, vol. 54, no. 1, pp. 14–33, 2007.
  - [24] Y. Zhang, X. Yu, M. Bi, and S. Xu, "An adaptive neural PID controller for torque control of hybrid electric vehicle," in *2011 6th International Conference on Computer Science & Education (ICCSE)*, 2011, pp. 901–903.
  - [25] M. D. Zeiler, "ADADELTA: An Adaptive Learning Rate Method," *arXiv preprint arXiv:1212.5701*, 2012.
  - [26] N. Qian, "On the momentum term in gradient descent learning algorithms," *Neural Networks*, vol. 12, no. 1, pp. 145–151, 1999/01/01/ 1999.
  - [27] D. P. B. Kingma, Jimmy, "Adam: a Method for Stochastic Optimization,," *International Conference on Learning Representations*, 12/2014 2015.
  - [28] H. Jin-Quan and F. L. Lewis, "Neural-network predictive control for nonlinear dynamic systems with time-delay," *IEEE Transactions on Neural Networks*, vol. 14, no. 2, pp. 377–389, 2003.

## 부 록

### A.1 실험에 사용된 전동기 제정수

표 1 1kW 표면부착형 전동기 제정수

항목	표시	값
정격 용량	P	1kW
극 수	Pole	4극
직류단 전압	$V_{dc}$	310V
정격 전류	$I_{rating}$	5A
정격 속도	$\omega_r$	3000r/min
상 저항	$R_s$	$0.5\Omega$
상 인덕턴스	$L_s$	3mH
역기전력 상수	$\lambda_f$	0.085Wb

### A.2 실험에 사용된 인버터 제정수

표 2 IGBT 인버터 (PS21A79)

항목	표시	값
직류단 전압	$V_{dc}$	310V
정격 전류	$I_{rating}$	50A
정격 스위치 주파수	$T_{sw}$	20kHz
데드 타임	$T_{dead}$	2.6us

# ABSTRACT

3 phase 2 level voltage source inverter has been widely used to drive AC machines. However, due to the characteristics of the voltage source inverter, there is a disadvantage that if two switches in a certain leg are turned on at the same time, it leads to a short circuit fault. To overcome this shortcoming, a dead zone is inserted while the switching state changes.

This dead zone makes a voltage duty change, which causes a pole voltage different from the command pole voltage to be applied. This effect causes a deteriorating the performance of the commonly used linear controllers. From the controller's point of view, changed voltage can be interpreted as a disturbance, which reduces the control bandwidth or generates a 6 order harmonic ripple over the fundamental frequency.

In order to solve the effect of the existing dead zone, existing methods use steady state pole voltage error data by phase current which is preliminary measured through current control on the standstill AC machine. These methods are effective when the magnitude of the current is large enough, however it has a detrimental effect on the low level current control. This is because the current at the sampling instant cannot represent the average current in the dead zone interval. Therefore, it is necessary to predict the dead zone current with information at the sampling instant. In the previous research, the linear model was used to predict the current, but the current waveform varies in the form of exponential function, so that it cannot be predicted with the linear model.

Therefore, in this paper, a method, Deep Learning, to approximate the nonlinear voltage to compensate the inverter nonlinear disturbance is proposed. Deep Learning is a field which applies parameter optimization algorithm to an artificial neural network. An artificial neural network is a



system that interpolates various systems including nonlinear activation functions according to the size of input variable states. Therefore, if the number of neuron is not limited, theoretically any time-invariant nonlinear function can be approximated. In the past, due to the influence of nonlinear functions, it was impossible to design parameters by intuition or frequency analysis, and therefore implementing it into the various control area is not easy. However, developing of processor computing power and developing the various optimization algorithms make it easy to adjust.

In this research, the nonlinearity of the inverter at low speed (0.2p.u) and low current (0.01p.u), which has limitations of complete compensation with conventional methods, was approximated with the neural network, and the performance was verified with 1kW SPMSM.